



Technische Fakultät  
Universität Bielefeld

# Vorlesung

# Softwaretest und -optimierung

Version 2012

---

Dr. Carsten Gnörlich

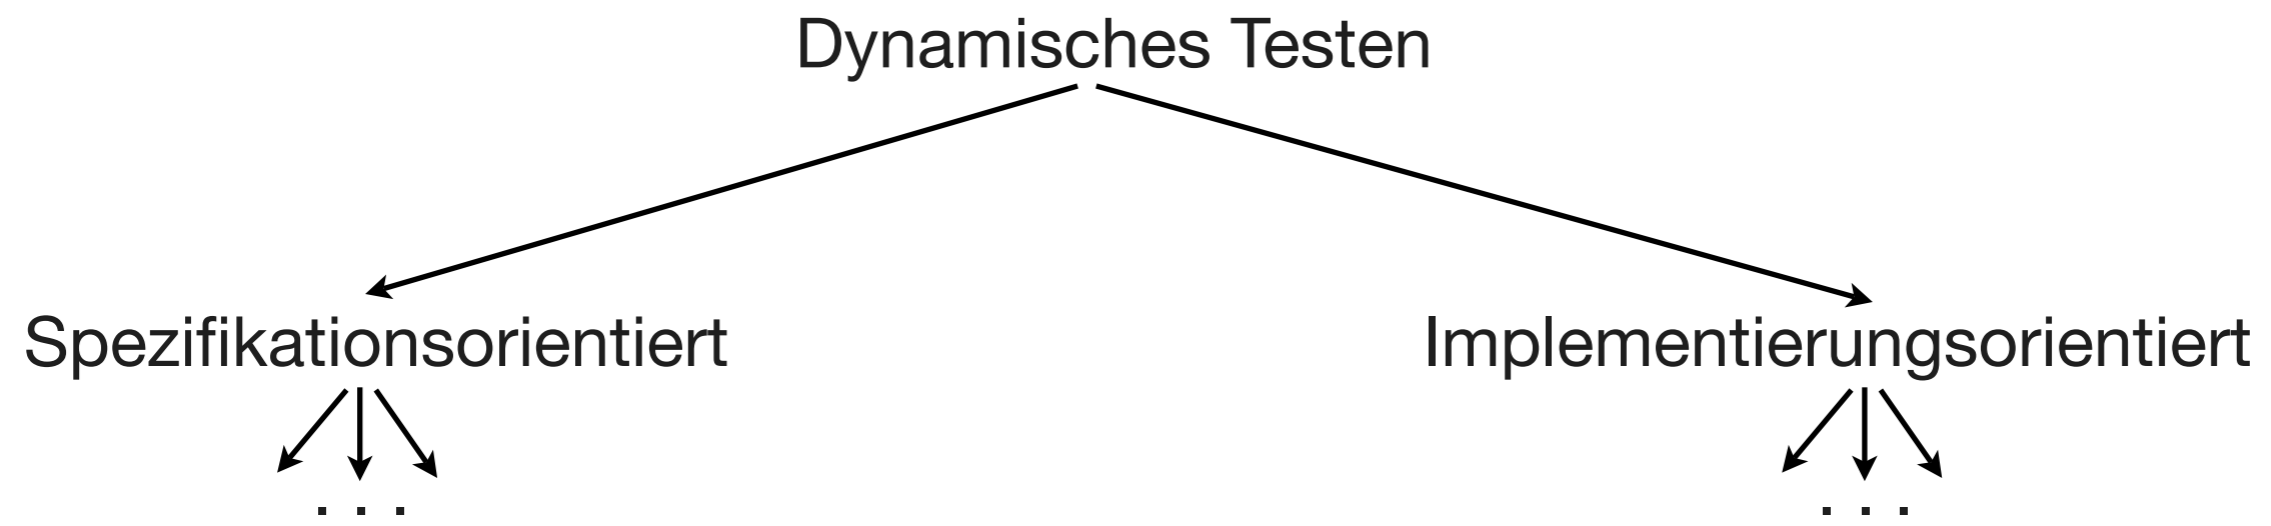
Rechnerbetriebsgruppe

Kap. 6 - Statische Analyse

(= Kap. 12 aus Riedemann)

# Einordnung

---

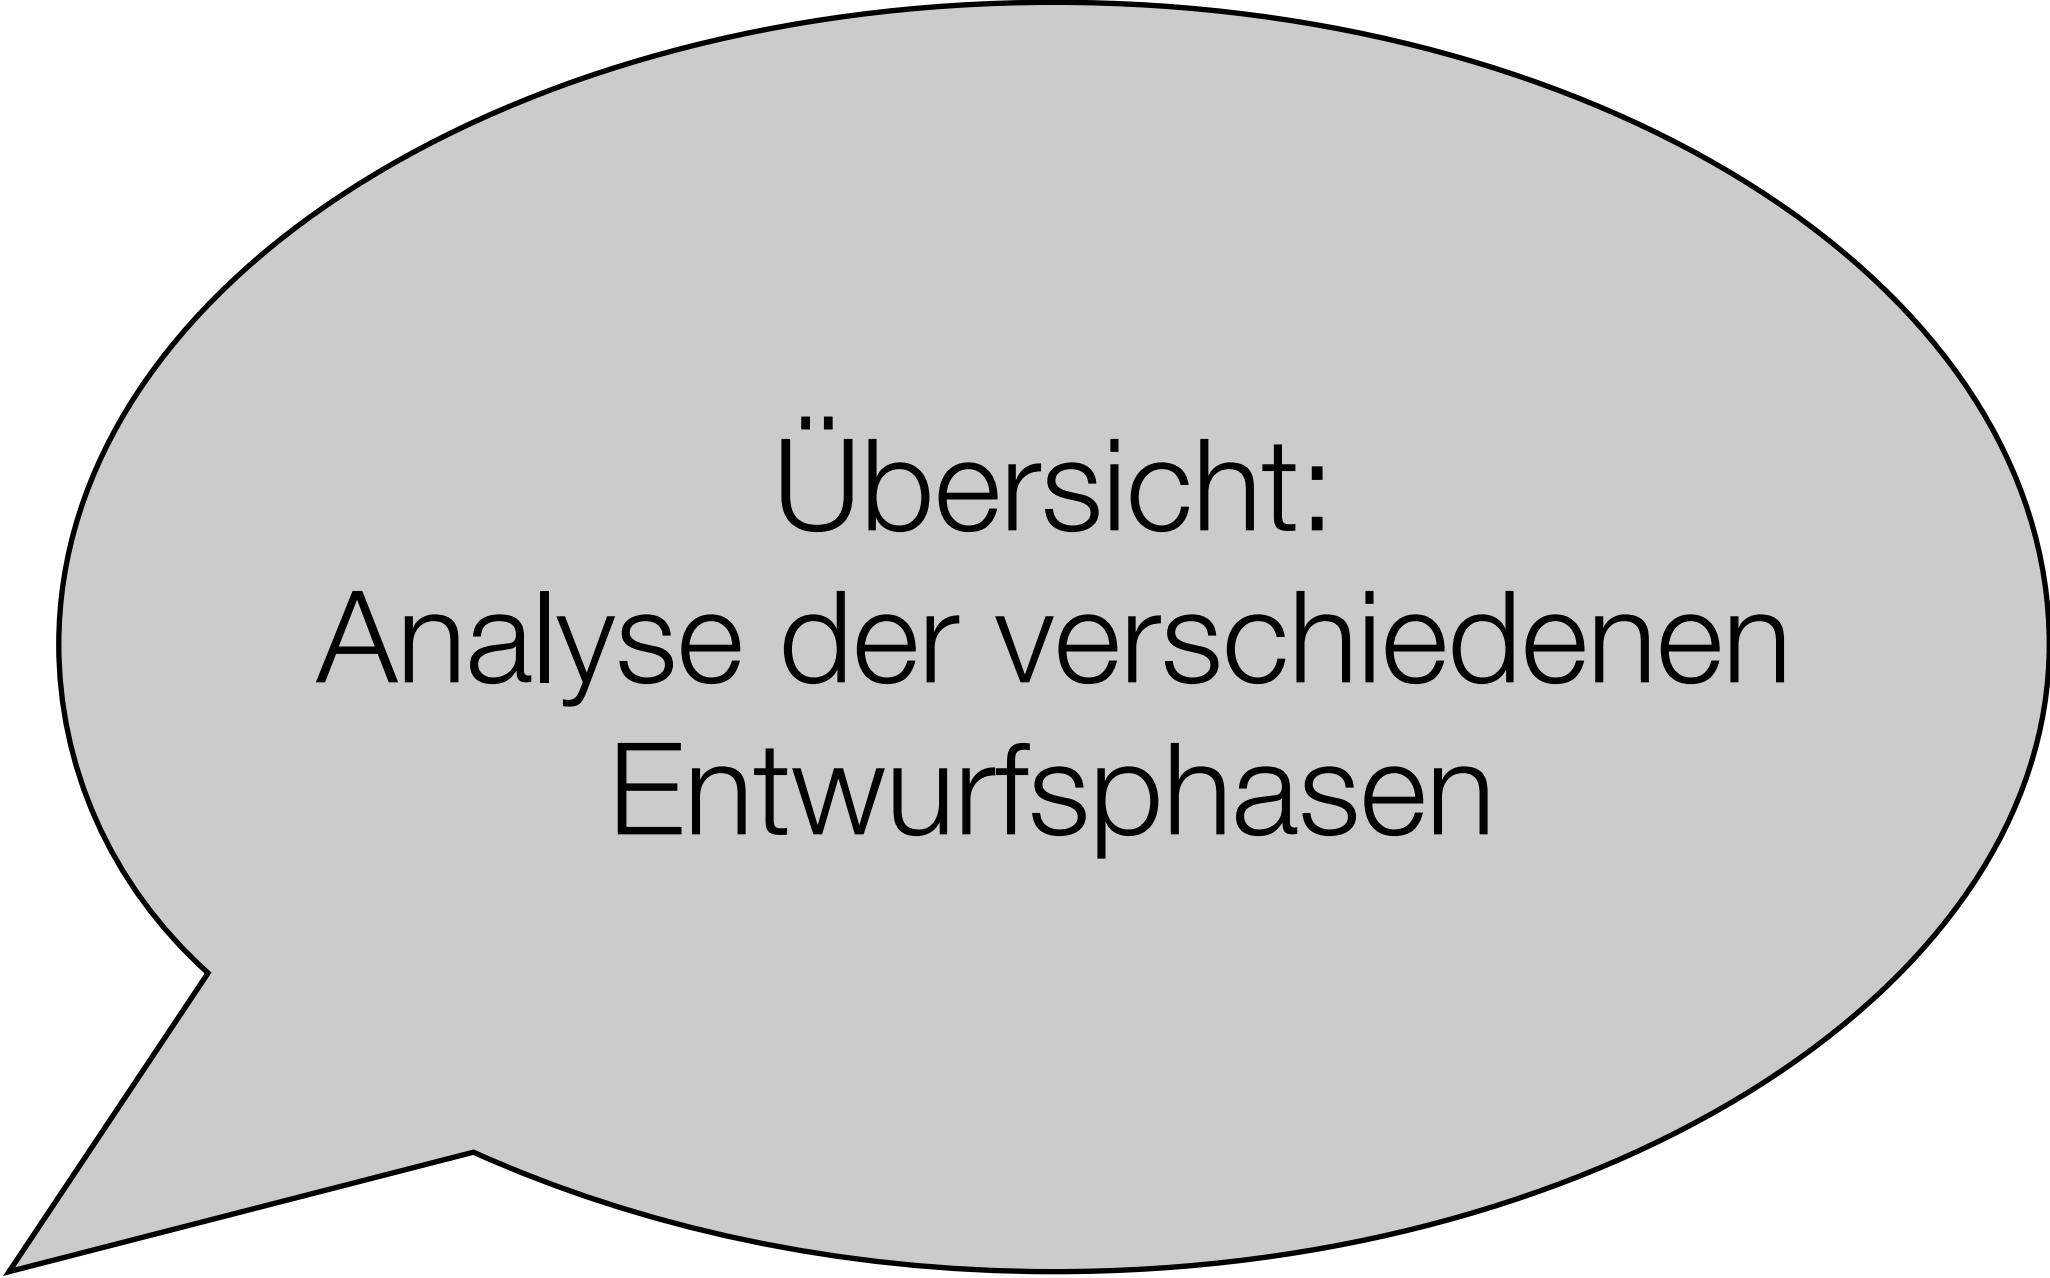


→ Testfälle generieren, Programm durch Ausführen testen

---

## Statische Analyse

→ Testen des Programms *ohne* tatsächliche Ausführung



Übersicht:  
Analyse der verschiedenen  
Entwurfsphasen

# Ziele der statischen Analyse

---

1. Anforderungsspezifikation, Systemspezifikation
2. Entwurfsspezifikation (Grob- und Feinentwurf)
3. Quellcode des Programms ←————— wird unser Schwerpunkt sein!
4. Objektcode des Programms

# Anforderungs-/Systemspezifikation

---

## Ziele der Untersuchung

- Notwendigkeit - für Systemziele
- Vollständigkeit - alle Eingaben, Ausgaben, Fälle berücksichtigt  
- Umgebung, Leistung, Benutzung spezifiziert?
- Konsistenz - Anforderungen untereinander  
- Nomenklatur, Maßeinheiten
- Durchführbarkeit - mit gegebener Technologie
- Testbarkeit - Entscheidbarkeit ob eine Anforderung erfüllt ist  
- Konstruktion von Testfällen

# Anforderungs-/Systemspezifikation

---

## Hilfsmittel zur Analyse

- Vergleich mit bestehenden Systemen / Standards
- mathematische Analyse algorithmischer / zeitlicher Anforderungen
- Simulationsmodelle / analytische Modelle
- automatische oder manuelle Dokumentationsanalyse

# Entwurfsspezifikation

---

## Ziele der Untersuchung

- Notwendigkeit - bzgl. Anforderungsspezifikation
- Vollständigkeit - bzgl. Anforderungsspezifikation
- Konsistenz - Schnittstellen, Ein-/Ausgabeformate, Datenbankschemata,...
- Korrektheit
  - Algorithmen, mathematische Gleichungen
  - Kontrolllogik
  - Leistung, Ressourcenverbrauch

# Entwurfsspezifikation

---

## Hilfsmittel zur Analyse

- Korrektheit: nur von Hand beweisbar
- Vollständigkeit / Notwendigkeit
  - im Groben automatisch per Numerierung:
    - Anforderungen eindeutig numerieren
    - bei Entwurfselementen zugehörige Anforderung angeben
- Konsistenz
  - bei Formalisierung von E/A-Variablen automatisch machbar
  - Problem: Synonyme, z.B. guint32 vs. unsigned int



# Quellcode

---

## Hilfsmittel zur Analyse

- Syntax (automatisch testbar)
- Datenflußfehler → LIVE/AVAIL-Algorithmen, zweite Stunde
- symbolische Ausführung
- Korrektheitsbeweise
- Informelle Analyse

# Objektkode

---

Für besonders kritische Software

- Vertraue nicht der Übersetzung Hochsprache → Maschinencode

Hilfsmittel

- Maschinencode rückübersetzen und erneut analysieren



# Automatische Analyse - Fehleranalysen

# Syntaxfehler

---

typischerweise trivial abgehandelt:

- Compiler
- Präprozessor

Hilfreich in C/C++:

`CFLAGS=-Wall -Werror`

→ alle Warnungen aktivieren und als Defekt betrachten

# Typ-Analyse

---

## Formen der Typisierung

- Statisch (z.B. C, C++, Java, Haskell)
- Dynamisch (z.B. LISP, Python, Ruby)

Sprachen sollten *typsicher* sein, also folgendes nicht zulassen:

`a = 5; b = "37"; c = a + b;` (Potentielle Ergebnisse: 42 oder „537“)

Wünschenswert:

- Zähler- und Indextypen (für Schleifen/Arrays)
- Maßeinheitstypen

```
int a:cm/s;  
int w:cm;  
int z:g;
```

```
a = w/z; /* Defekt */
```

# Lebensdauer und Gültigkeitsbereiche von Variablen

---

Beispiel:

```
char *ptr1 = strdup(„zeichenkette“);
```

```
if(*ptr1=='a')  
{ char *ptr2 = strdup(„neue kette“);  
  free(ptr1);  
}
```

```
printf(ptr2); /* Fehlermeldung zur Compilezeit */
```

```
printf(ptr1); /* Infektion/Fehlfunktion zur Laufzeit */
```

- Datenfluß-/Kontrollflußanalyse
- garbage collection statt *free()*

# Analyse von Prozeduren

---

## i) Prozeduren sind selbst Parameter (anderer Prozeduren)

- Typüberprüfung

## ii) Funktionsprozeduren

- dürfen keine Seiteneffekte haben (nur Rückgabewert)
- also z.B. keine globalen Variablen setzen

## iii) Parameteranzahl und -Typen

- Problem: Beim Linken von zwei Objektdateien wird nichts mehr geprüft

# Ereignisfolgen

---

Beispiele:

- `fopen()` vor `fread()`
- `fopen(name, „w“)` vor `fwrite()`

→ statische Überprüfung anhand der Kontrollflußwege

→ Zustandsdiagramm/endlichen Automaten bauen



# Programmstruktur-Analyse

---

i) Analyse ob das Programm strukturiert ist

- falls nein (gotos verwendet)
  - unerreichbare Anweisungen?
  - nicht verwendete label?

ii) Gibt es nicht ausführbare Wege?

iii) Terminierungsbedingungen von Schleifen

- datenunabhängige Schleifen: trivial
- datenabhängige Schleifen: Konvergenzbeweis von Hand

Datenabhängige Schleife: Indexvariable wird innerhalb der Schleife manipuliert

```
for(i=0; i<100; i++)  
{ ...  
  if(b) i--;      /* typischerweise unübersichtlich: keine gute Idee */  
  ...  
}
```

# Analyse von Programmierrichtlinien

---

- i) formale Richtlinien für Kommentare
- ii) Layout-Richtlinien, zum Beispiel Klammerstil
- iii) Einhaltung von Komplexitätsgrenzen
  - Kodelänge pro Modul / Funktion
  - Schachtelung von Schleifen / Fallunterscheidungen
- iv) Namenskonventionen, z.B. CamelCase vs. under\_score
- v) verbotene Konstrukte, z.B. nur „sichere“ Speicherverwaltung

```
char buffer[80];  
gets(buffer);
```

```
char *buffer = xmalloc(80);  
buffer = getline(buffer, 80, stdin);
```

# Ausdrucks-Analyse

---

i) Indexgrenzen bei Arrays, idealerweise wie in Pascal:

- `a: array[1..10] of int;`
- `b: [1..20];` (\* Indextyp \*)
- `a[b]` → Fehlermeldung zur Compilezeit

ii) Test von Fließkommazahlen auf (Un-)Gleichheit:

- `if(r == s)` → `if(fabs(r,s) < EPSILON)`

iii) Fehlende Klammern

- `a*b/c*d` → `((a*b)/c)*d` oder `(a*b)/(c*d)`

iv) Rechenfehler wie Division durch Null

# Defekte durch symbolische Ausführung aufdecken

---

Programmcode:

- ①  $y := x - 1$
- ② if  $x = 1$  then  $a = x/y$

Symbolische Ausführung:

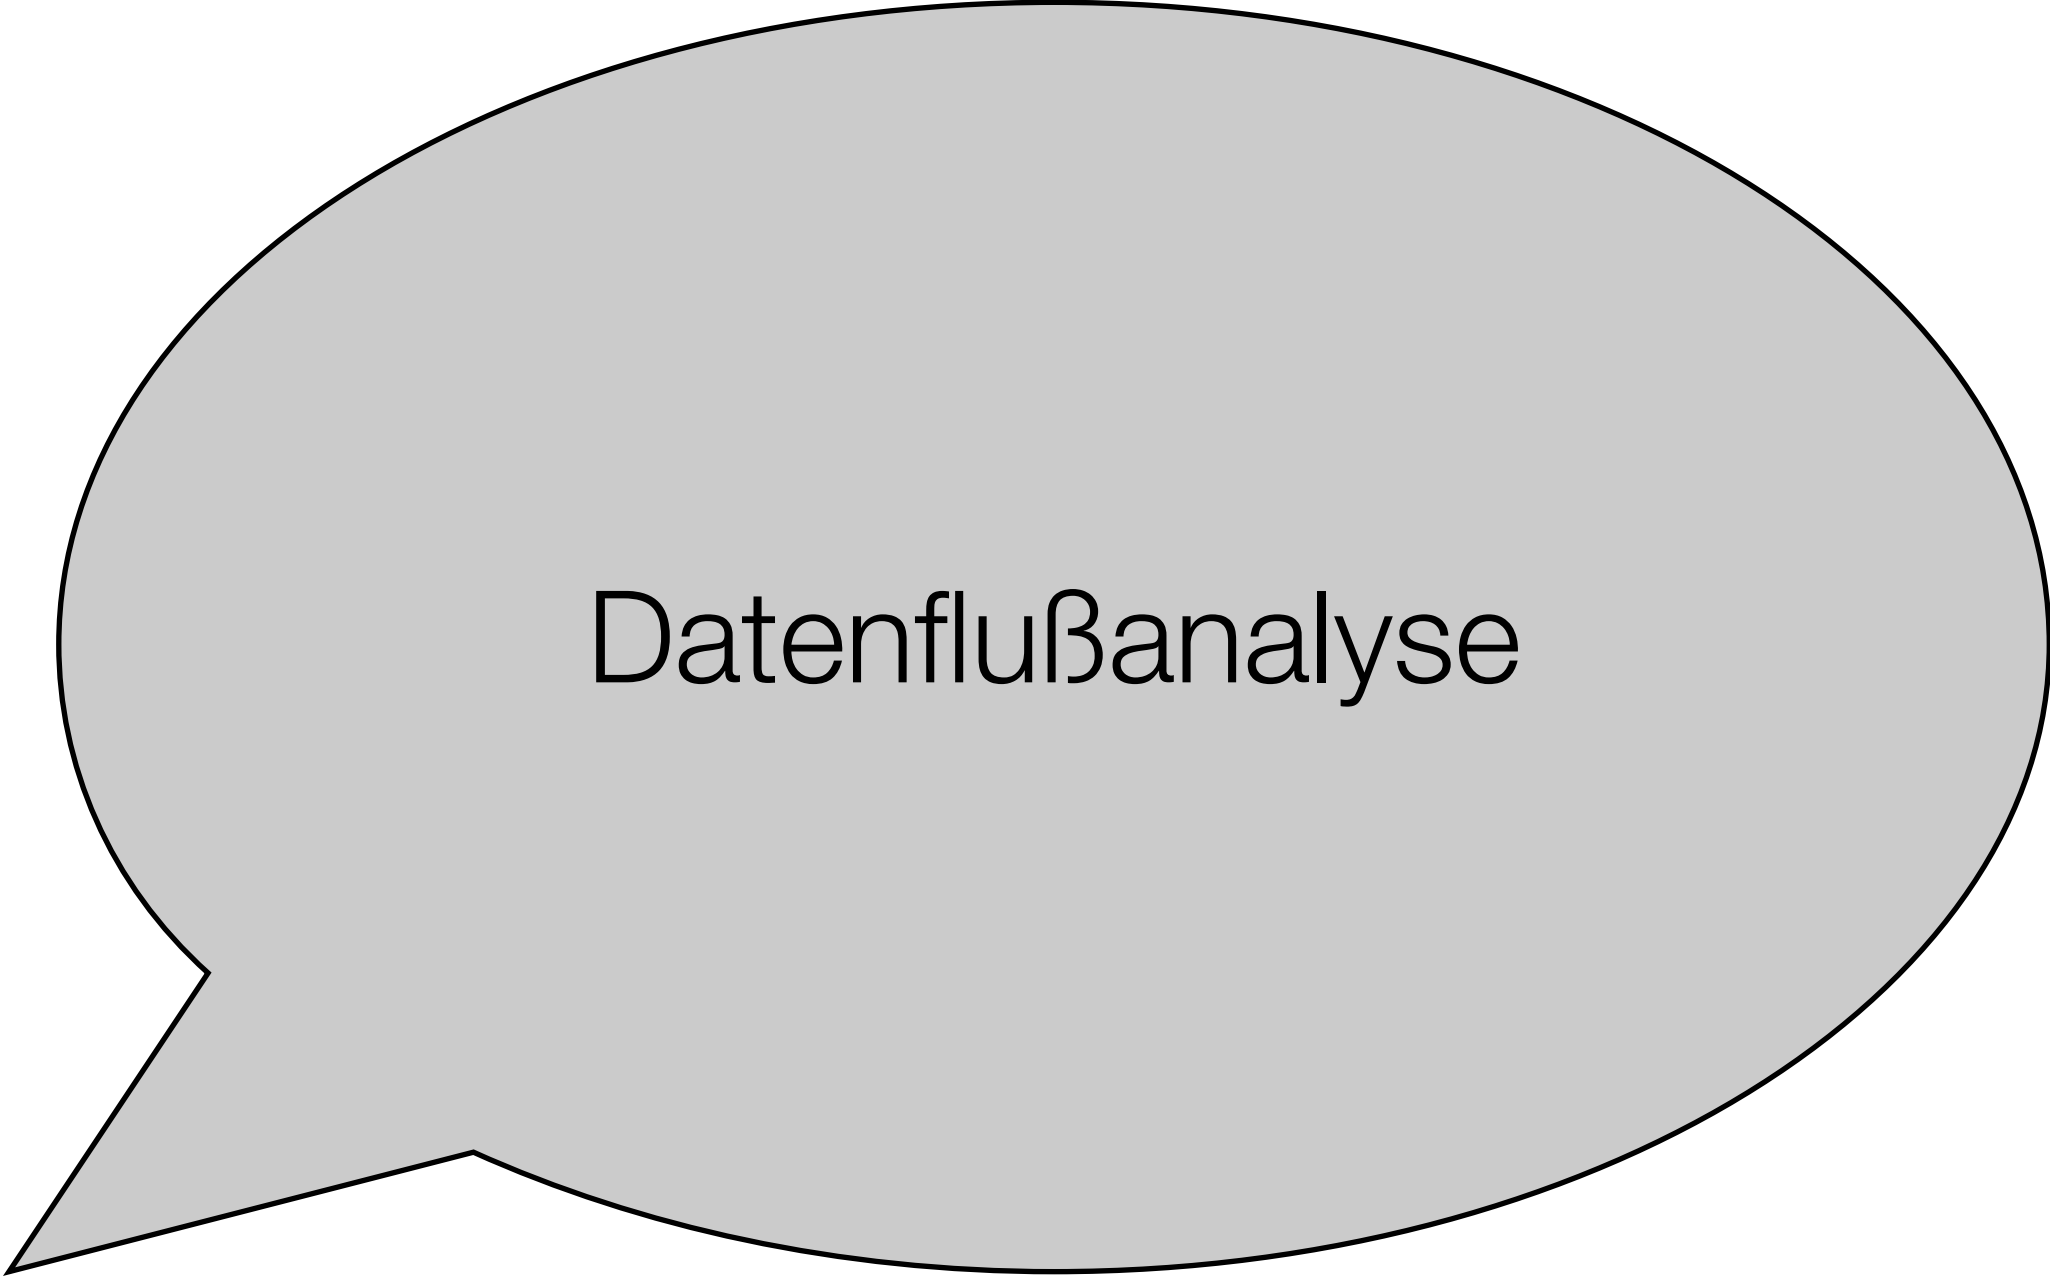
Substituiere  $x \leftarrow \alpha$

- ①  $y := \alpha - 1$
- ② „if“ soll erfüllbar sein, also wähle  $\alpha = 1$

$$x = \alpha = 1$$

$$y = \alpha - 1 = 0$$

$$a = 1 / 0 \Rightarrow \text{Division durch Null aufgedeckt}$$



# Datenflußanalyse

# Vorgehensweise

---

Benötigt: Datenflußgraph (aus der letzten Woche)

1. Alle Pfade durch den Datenflußgraphen durchlaufen
2. Für jeden Pfad und jede Variable notieren, wenn sie definiert, referenziert oder undefiniert wird (mit Abkürzungen d,r,u)
  - ergibt Pfadausdruck über {d,r,u} für jede Variable
3. Anomalie liegt bei folgenden Pfadausdrücken vor:
  - i) ..ur.. undef/ref - Anomalie
  - ii) ..dd.. def/def - Anomalie
  - iii) ..du.. def/undef - Anomalie

# Mögliche Probleme

---

## 1. Prozeduraufrufe

- Aufblähen des Datenflußgraphen; insbes. bei globalen Variablen

## 2. Dynamisch wachsende Strukturen (Listen, Bäume, Graphen)

- als monolithische Einheit (wie eine Variable) betrachten

## 3. Arrays

- typischerweise nicht als  $n$  einzelne Variablen behandelbar - Bsp:  $a[i]$
- wie oben als monolithische Einheit nehmen

## 4. Schleifen

- Anzahl der zu betrachtenden Wege? → siehe LIVE/AVAIL-Algorithmus

# LIVE and AVAIL-Algorithmus (1)

---

Annotation des Kontrollflußgraphen mit folgenden Mengen:

$A \in \text{gen}(n) \iff$  Token  $A$  wird in Knoten  $n$  „erzeugt“

$A \in \text{kill}(n) \iff$  Token  $A$  wird in Knoten  $n$  „verbraucht“

$A \in \text{null}(n) \iff$  Token  $A$  wird in Knoten  $n$  nicht verändert

Sei  $\text{tok}$  die Menge aller Tokens, dann gilt:

$$\text{gen}(n) \cup \text{kill}(n) \cup \text{null}(n) = \text{tok}$$

$$\text{gen}(n) \cap \text{kill}(n) \cap \text{null}(n) = \emptyset$$



# LIVE and AVAIL-Algorithmus (2)

---

Bildung von Pfadausdrücken  $P(A; w)$  für Weg  $w$  und Variable  $A$

- jeweils Buchstaben  $g, k, n$  für die besuchten Knoten notieren

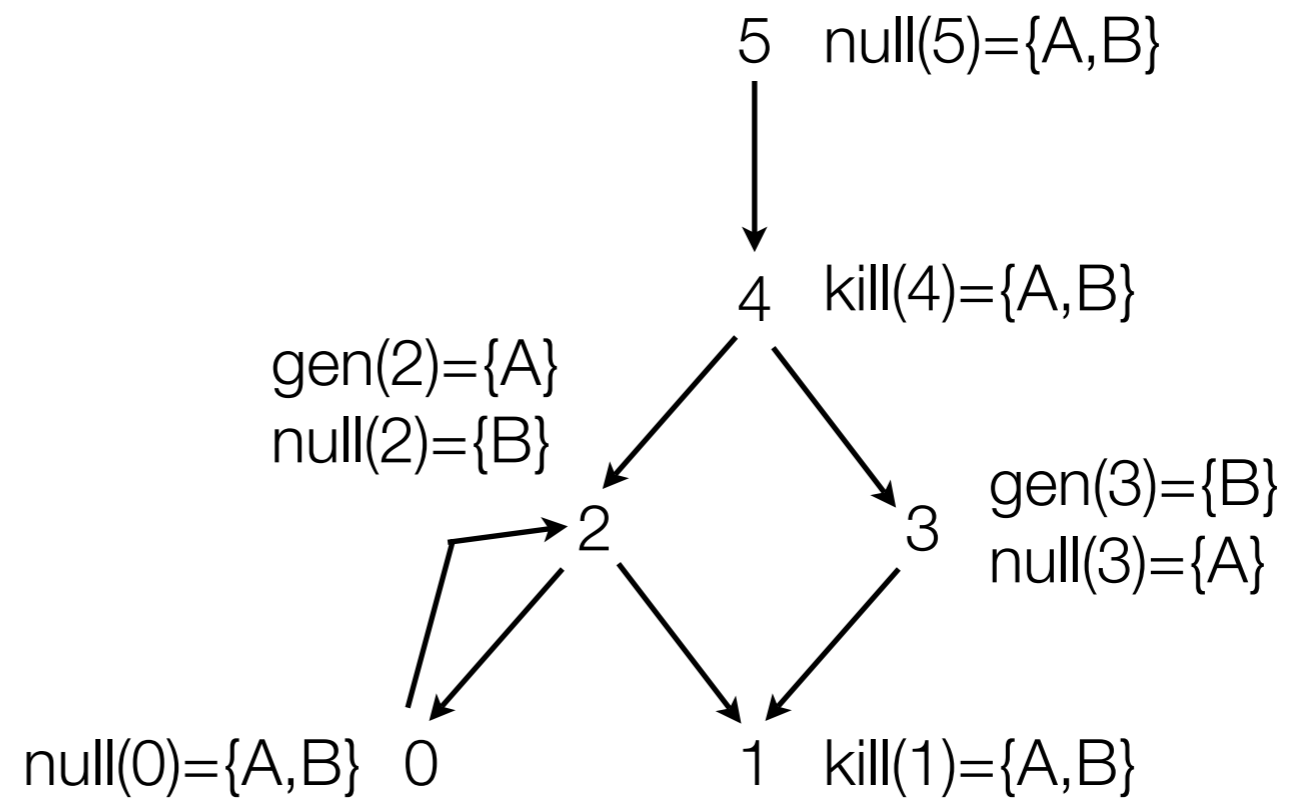

Reduzierter Pfadausdruck:

- Symbole  $n$  weglassen

Spezielle Notationen mit Hilfe regulärer Ausdrücke:

- $P(A; k \rightarrow)$  : Alle möglichen Wege die vom Knoten  $k$  ausgehen
- $P(A; \rightarrow k)$  : Alle möglichen Wege die zum Knoten  $k$  hinführen

# Beispiel



# LIVE and AVAIL-Algorithmus (3)

---

(Informelle Definition)

$A \in \text{live}(k) \Leftrightarrow$  *einer* der Wege, der von Knoten  $k$  ausgeht, beginnt mit „g“

→  $A$  kann in der Zukunft auf wenigstens einem Weg generiert werden

$A \in \text{avail}(k) \Leftrightarrow$  *alle* Wege, die zu  $k$  hinführen, enden mit „g“

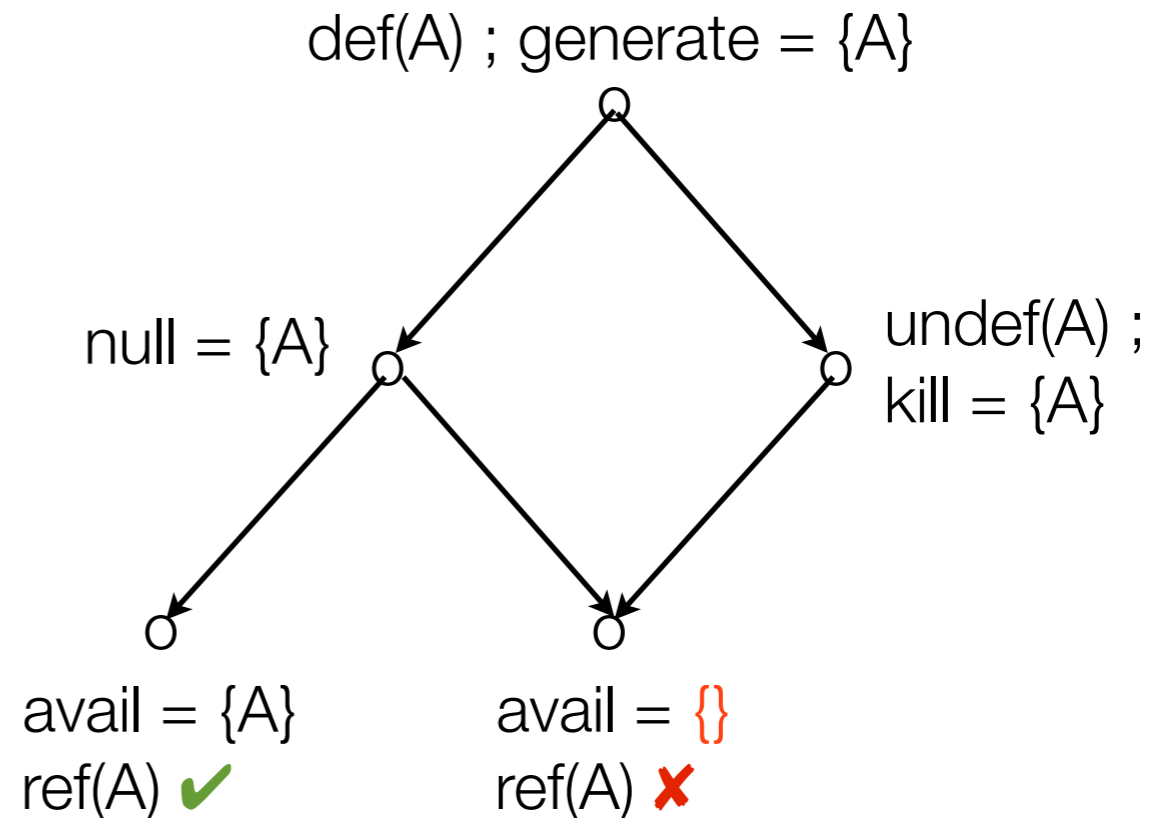
→  $A$  ist in  $k$  immer verfügbar, egal auf welchem Weg  $k$  erreicht wird

Berechnung: einfache iterative Algorithmen; siehe Riedemann Seite 320

# Undef/Ref-Anomalie finden

Verwende:  $\text{generate}(k) = \text{def}(k)$   
 $\text{kill}(k) = \text{undef}(k)$

Berechne:  $\text{avail}(k)$




Falls  $A \notin \text{avail}(k)$  und  $A \in \text{ref}(k) \Rightarrow$  Undef/Ref-Anomalie gefunden

Begründung:  $A \notin \text{avail}(k) \Rightarrow$  ein Vorgänger von  $K$  endet auf kill/undef

# Def/def-Anomalie finden

Verwende:  $\text{generate}(k) = \text{def}(k)$   
 $\text{kill}(k) = \text{ref}(k) \cup \text{undef}(k)$

Berechne:  $\text{live}(k)$



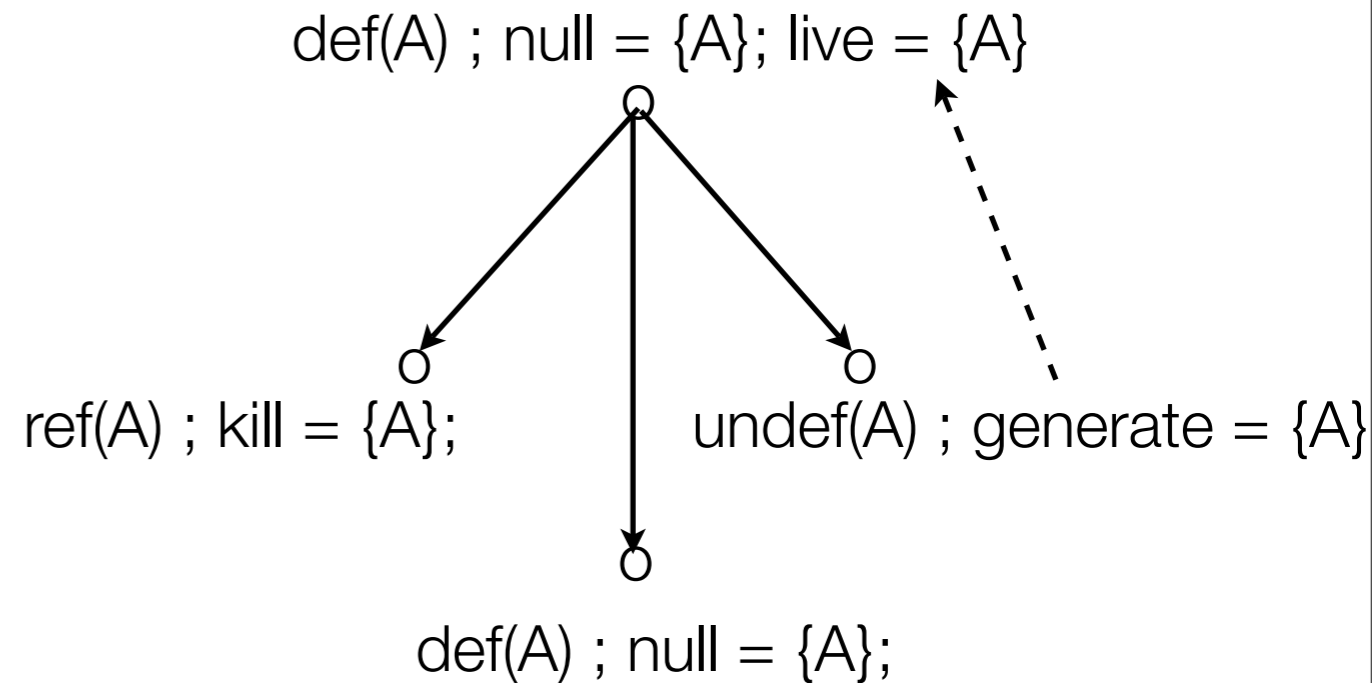
Falls  $A \in \text{live}(k)$  und  $A \in \text{def}(k) \Rightarrow \text{def/def-Anomalie}$

Begründung:  $A \in \text{live}(k) \Rightarrow$  es findet unmittelbar mindestens eine weitere Def.

# Def/undef-Anomalie finden

Verwende:  $\text{generate}(k) = \text{undef}(k)$   
 $\text{kill}(k) = \text{ref}(k)$

Berechne:  $\text{live}(k)$



Falls  $A \in \text{live}(k)$  und  $A \in \text{def}(k) \Rightarrow \text{def/undef-Anomalie}$

Begründung:  $A \in \text{live}(k) \Rightarrow$  es findet unmittelbar mindestens ein undef



# Symbolische Ausführung

# Symbolisches Ausrechnen von Ausdrücken/Seq.

---

Normale Programmausführung rechnet mit konkreten Werten

- Erweiterung: Rechne mit symbolischen Eingabewerten
- entsprechend weiterrechnen mit resultierenden Ausdrücken

Beispiel: Symbolisches Ausrechnen von Ausdrücken / Sequenzen

$C := A + 2 * B$

$D := C - A$

$c = a + 2b$

$d = a + 2b - a$

$d = 2b$

| Setze Symbole a,b für A,B ein

| Setze symbol. Ausdruck für C und a für A ein

| Vereinfachung

(Vorsicht: Rundungsfehler bei Fließkommazahlen)



# Symbolisches Ausrechnen von Kontrollelementen

---

Exemplarisch am Beispiel **if B then A1 else A2**

Als Resultat des Ausrechnens von B kann herauskommen:

- i) B ist immer wahr  $\Rightarrow$  symbol. Wert der Anweisung ist A1
  - ii) B ist immer falsch  $\Rightarrow$  symbol. Wert der Anweisung ist A2
  - iii) sonst: Pfadbedingungen für die Fälle wahr und falsch angeben
    - $\rightarrow$  Baumstruktur von Wegen
    - $\rightarrow$  Pfadbedingungen in den Zweigen mitschleppen / kombinieren
- bei Schleifen: Anzahl Iterationen begrenzen oder Induktionsbeweis

# Komplexeres Beispiel

---

Exemplarischer Weg: 1, 2, 3 true, 4, 5 true, 6

① read a,b

②  $x = a * b + 2$

③ if  $x > 100$

    then  $x = 100 - x$

④  $x = x - 50$

⑤ if  $x < 0$

    then  $x = 0$

⑥ print x

②  $x = a * b + 2$

③ true  $\rightarrow a*b+2 > 100 \Leftrightarrow a*b > 98$

$x = 100 - (a*b+2) \Leftrightarrow x = 98 - a*b$

④  $x = 98 - a*b - 50 \Leftrightarrow x = 48 - a*b$

⑤ true  $\rightarrow 48 - a*b < 0 \Leftrightarrow a*b > 48$

da bereits  $a*b > 98$  aus ③ folgt  $\Rightarrow$  ⑤ immer wahr

$\Rightarrow x = 0$

⑥ symbolische Ausgabe ist 0

# Symbolisches Ausrechnen von Aufrufen

---

a) Symbolisches Ausrechnen gemäß Parameterbelegung und Prozedurkörper:

```
int foo(int a, int b) { return a + b; }
```

```
a := foo(x,y) /* x,y in Prozedurkörper einsetzen */
```

... mit  $a = x+y$  weiterrechnen ...

b) Ausdruck nicht weiter auflösen

```
a := foo(x,y);
```

```
b := 2*foo(x,y);
```

```
c := a + b;
```

... mit  $c = 3*foo(x,y)$  weiterrechnen ...

# Vorteile der symbolischen Ausführung

---

- Ein symbolischer „Test“ deckt viele reale Testdaten ab
- findet Defekte, bei denen für eine Teilmenge der Eingaben falsche Ergebnisse berechnet werden
- man findet nicht ausführbare if-Zweige
- unterstützt Finden von Schleifen-Invarianten

# Nachteile der symbolischen Ausführung

---

- Überprüfen der Ergebnisse ist schwieriger
  - insbesondere bei nicht aufgelösten Prozeduraufrufen
  - ungenügend vereinfachte Ausdrücke
- Programmiersprache muß formal definiert sein
- Symbolischer Interpreter muß vorhanden sein
- Umformungen können Maschineneigenschaften verdecken (Rundungsfehler)
- es wird ein Theorembeweiser benötigt (der nicht vollständig sein kann)
- keine Leistungsmessung

# Vorteile der statischen Analyse

---

- keine Codeänderungen, Treibermodule notwendig
- Analyse unausführbarer Systeme möglich  
(unvollständige / noch nicht lauffähige bzw. existierende Systeme)
- Mehrere Defekte können in einem Durchgang gefunden werden
- findet auch neue / unerwartete Klassen von Defekten

# Grenzen der statischen Analyse

---

- zeitliche Zusammenhänge nur begrenzt analysierbar:

```
r = 0;
for(i=1; i<100; i++)
{  if(i==1) a=5;
   r=a+(i+1)+r;      /* keine undef/ref-Anomalie bzgl. a ! */
}
```

- Diagnose nicht automatisierbar  
(Warnungen/potentielle Defekte von Hand bewerten)
- Abhängigkeit vom Programmierstil; siehe obiges Beispiel

# Ende der heutigen Vorlesung

---

**Danke fürs Zuhören!**

**Bis nächste Woche :-)**