SAP AG, Walldorf, 2004-06-24

Warum stürzt mein Programm ab?

Automatisches Isolieren von Fehlerursachen

Andreas Zeller

Lehrstuhl Softwaretechnik
Universität des Saarlandes, Saarbrücken







Eine wahre Geschichte

Wir betrachten das folgende C-Programm:

```
double bug(double z[], int n) {
  int i, j;
  i = 0;
  for (j = 0; j < n; j++) {
    i = i + j + 1;
    z[i] = z[i] * (z[0] + 1.0);
  }
  return z[n];
}
```

bug.c läßt den GNU-Compiler (GCC) abstürzen:

```
linux$ gcc-2.95.2 -O bug.c
gcc: Internal error: program cc1 got fatal signal 11
```

Welcher Fehler verursacht dieses Fehlschlagen?







Fehler

Was ist der Fehler in GCC?

> *Ein **Fehler** ist eine Abweichung vom Korrekten, Richtigen, oder Wahren.*
>
> — IEEE Standard Glossary of SE Terminology

Um zu zeigen, dass etwas ein Fehler ist, müssen wir *die Abweichung zeigen:*

- *einfach* für das konkrete Fehlschlagen
- *schwierig* für den Programmcode

Ansatz: *Deduktion* – Schließen vom abstrakten (Code) auf das konkrete (Ablaufen): Statische Analyse, Verifikation, …

Wo weicht GCC ab – und wovon?







Ursachen

Was ist die Ursache des GCC-Absturzes?

> *Eine **Ursache** eines Ereignisses („**Wirkung**“) it ein vorangegangenes Ereignis, ohne dies das Ereignis nicht aufgetreten wäre.*
>
> — Microsoft Encarta

Um Kausalität zu zeigen, müssen wir zeigen, dass

1. **die Wirkung auftritt, wenn die Ursache auftritt**
2. **die Wirkung *ausbleibt*, wenn die Ursache *ausbleibt*.**

Allgemeiner Ansatz: *Experimentieren* – Konstruktion einer *Theorie* aus einer Folge von Experimenten (Läufen)

Können wir Experimentieren automatisieren?

Isolieren von Fehlerursachen

Mit systematischem Testen können wir die fehlerverursachende Eingabe isolieren:

#	GCC-Eingabe	Test
1	double **bug**(…) { int i, j; $i = 0$; for (…) { …} …}	✘
5	double **bug**(…) { int i, j; $i = 0$; for (…) { …}…}	✘
⋮		
19	… $z[i] = z[i] * (z[0] + 1.0);$ …	✘
18	… $z[i] = z[i] * (z[0] + 1.0);$ …	✔
⋮		
4	double **bug**(…) { int i, j; $i = 0$; for (…) { …} …}	✔
3	double **bug**(…) { int i, j; $i = 0$; for (…) { …} …}	✔
2	double **bug**(…) { int i, j; $i = 0$; for (…) { …} …}	✔

$+ 1.0$ ist Fehlerursache – nach nur 19 Tests ($\approx$ 2 Sekunden)

Delta Debugging

Delta Debugging isoliert *fehlerverursachende Unterschiede:*

Eingaben. Der Mozilla-Browser stürzt beim Drucken ab —
Ursache: 1 von 900 HTML-Zeilen (<SELECT>)

A. Zeller + R. Hildebrandt, *Simplifying and Isolating Failure-Inducing Input*, IEEE TSE 28(2), 2002

Code-Änderungen. DDD läuft nicht mehr mit GDB 4.17 —
Ursache: 1 von 8.721 Änderungen (`infcmd.c:1239`).

A. Zeller, *Yesterday, my program worked. Today, it does not. Why?*, Proc. ACM ESEC/FSE 1999

Threads. *Data Race* in parallelem Raytracer —
Ursache: 1 von 3,8 Mrd. Thread-Wechseln (`Scene.java:91`)

J.-D. Choi + A. Zeller, *Isolating Failure-Inducing Thread Schedules*, Proc. ACM ISSTA 2002

Vollautomatisches, rein testbasiertes Verfahren.

Was passiert in GCC?

Der Unterschied $+1.0$ ist erst der Anfang
einer *Ursache-Wirkungs-Kette* im GCC-Lauf.

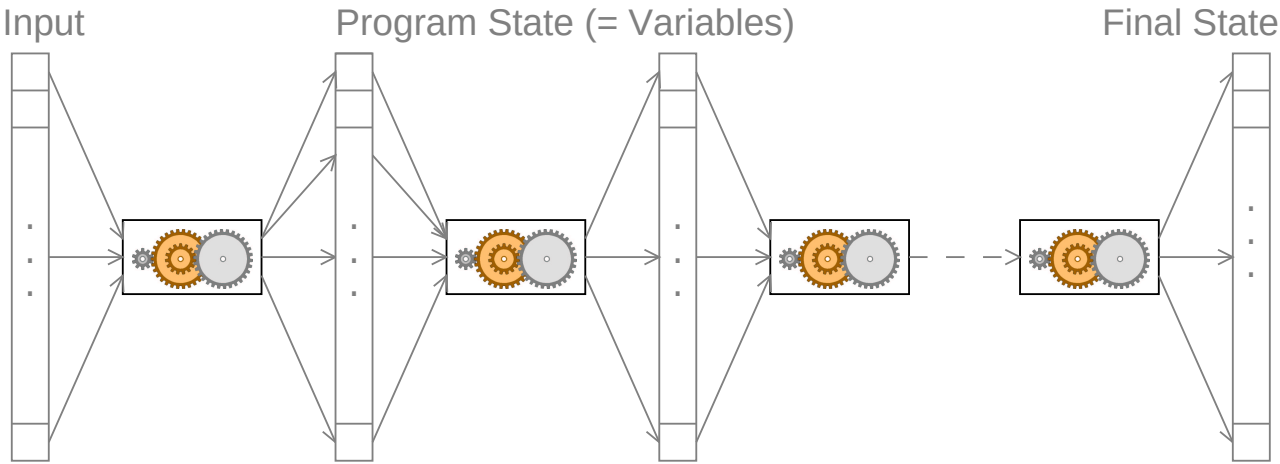

Was passiert in GCC?

Der Unterschied $+1.0$ ist erst der Anfang
einer *Ursache-Wirkungs-Kette* im GCC-Lauf.

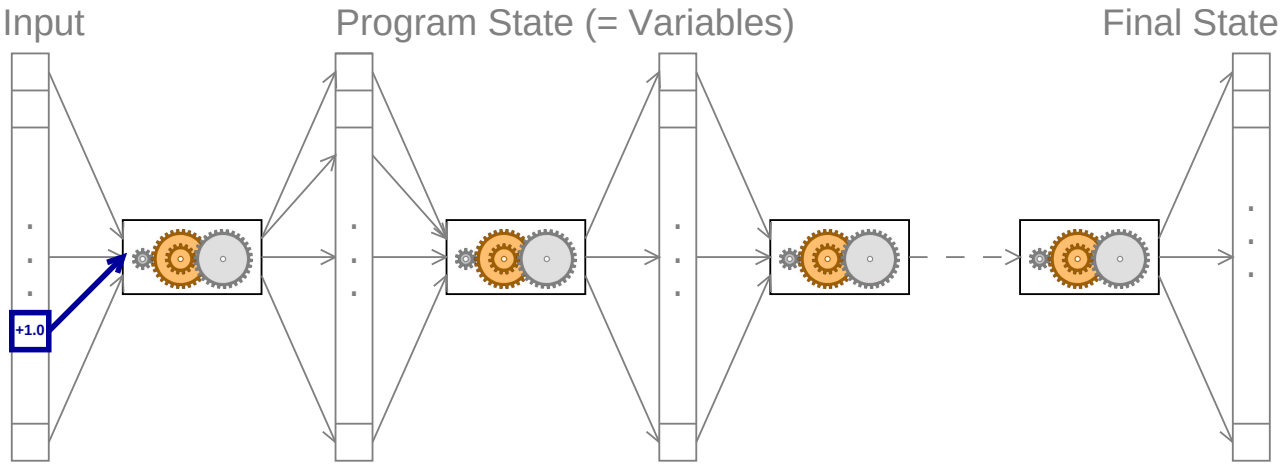

Was passiert in GCC?

Der Unterschied $+\,1.0$ ist erst der Anfang
einer *Ursache-Wirkungs-Kette* im GCC-Lauf.

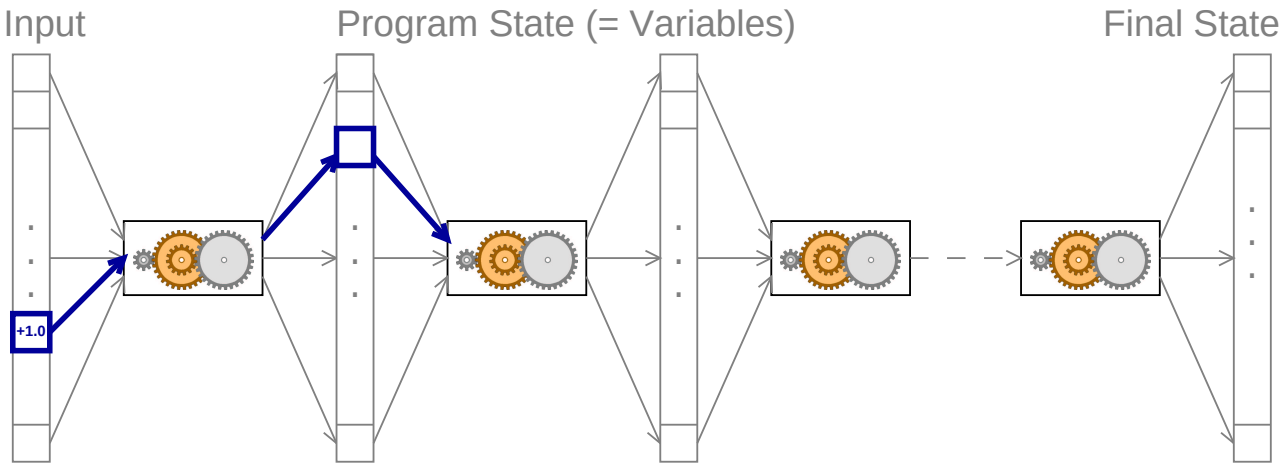

Was passiert in GCC?

Der Unterschied $+\,1.0$ ist erst der Anfang
einer *Ursache-Wirkungs-Kette* im GCC-Lauf.

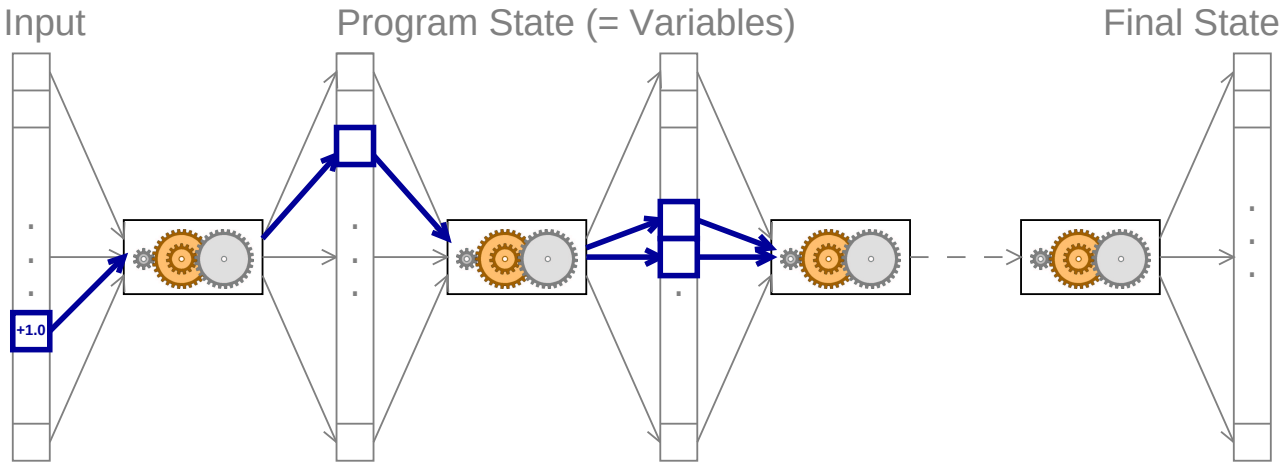

Was passiert in GCC?

Der Unterschied $+1.0$ ist erst der Anfang
einer *Ursache-Wirkungs-Kette* im GCC-Lauf.

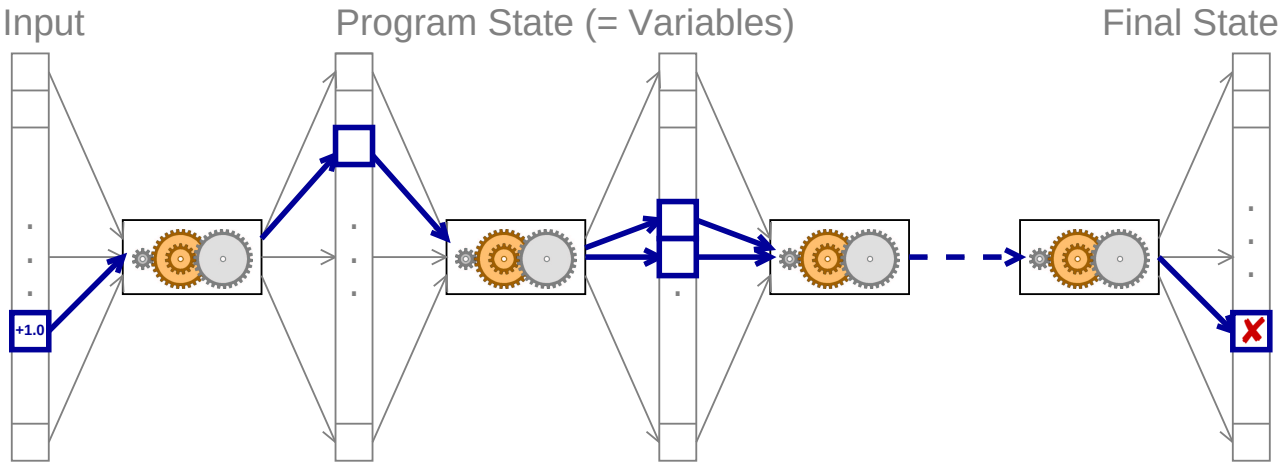

Um den Fehler zu reparieren, müssen wir diese Kette *brechen*.

Datenströme verfolgen

Mit klassischer *Programmanalyse* kann man verfolgen, wie sich Daten in Programmen fortpflanzen.

Voraussetzung: Vollständiges Wissen über gesamten Code und seine Semantik ⇒ gut für kleine, abgeschlossene Programme.

Aber: Echte Programme sind *opak, parallel, verteilt, dynamisch, mehrsprachig* – oder einfach obskur:

```
struct foo {
  int tp, len;
  union {
    char   c[1];
    int    i[1];
    double d[1];
  }
}
```

```
// Allocate string
int len = 200;
int bytes = len + 2 * sizeof(int);
foo *x = (foo *)malloc(bytes);
x->tp = STRING;
x->len = len;
strncpy(x->c, "Some string", len);
```

Kleine Ursache, große Wirkung

Auswirkungen sammeln sich während der Ausführung an:

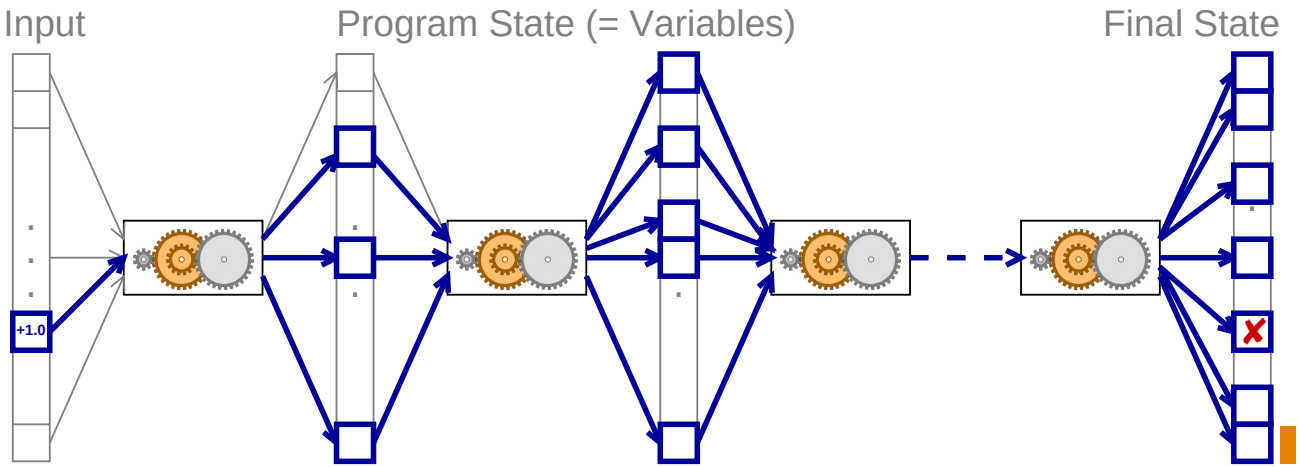

Ansatz: *relevante Zustandsunterschiede* bestimmen!

Relevante Zustandsunterschiede

Mit einem Debugger (GDB) können wir den Zustand beobachten und verändern.

Beispiel: GCC-Zustand in der Funktion *combine_instructions*

#	reg_rtx_no	cur_insn_uid	last_linenum	first_loop_store_insn	test
1	32	74	15	0x81fc4e4	✘
			?		
5	32	74	15	0x81fc4a0	✔
4	32	74	14	0x81fc4e4	?
3	32	74	14	0x81fc4a0	✔
2	31	70	14	0x81fc4a0	✔

Folge: *Strukturelle Unterschiede* bestimmen und anwenden!

Der GCC-Speichergraph

IGOR-Prototyp betrachtet Programmzustand als *Graph*:
Knoten sind *Variablen*, Kanten *Verweise*

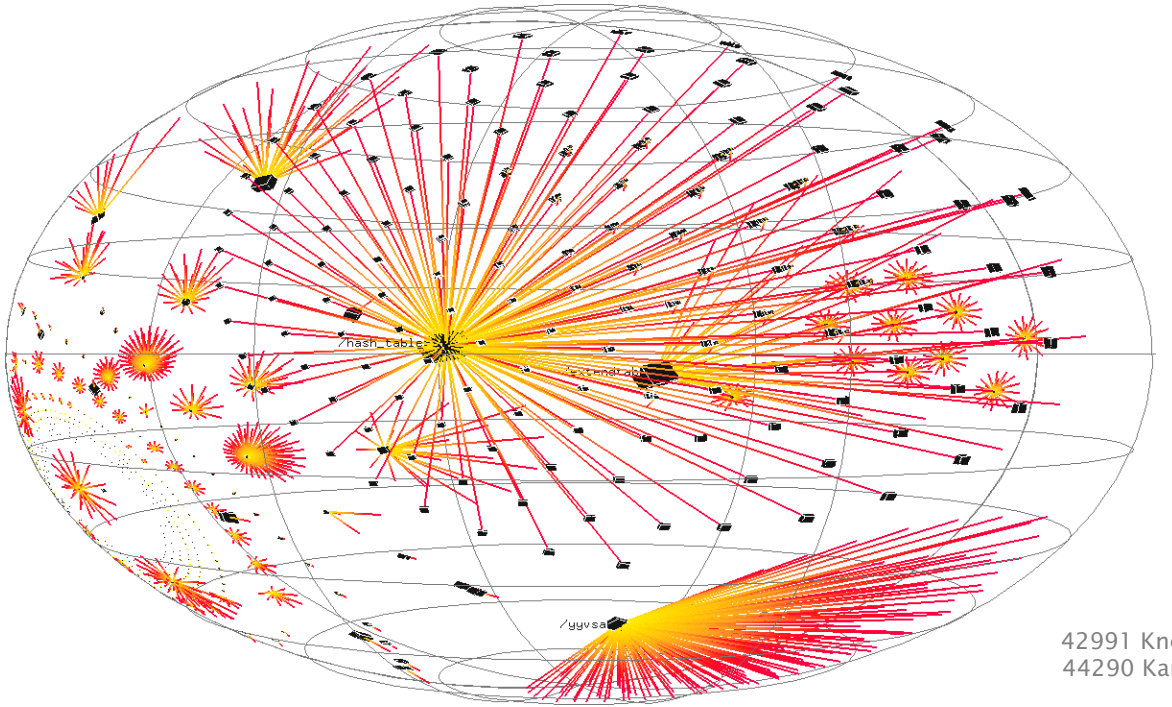

42991 Knoten
44290 Kanten

Strukturelle Unterschiede

IGOR kann strukturelle Graph-Unterschiede berechnen:
Δ_{15} erzeugt eine Variable, Δ_{20} löscht eine andere

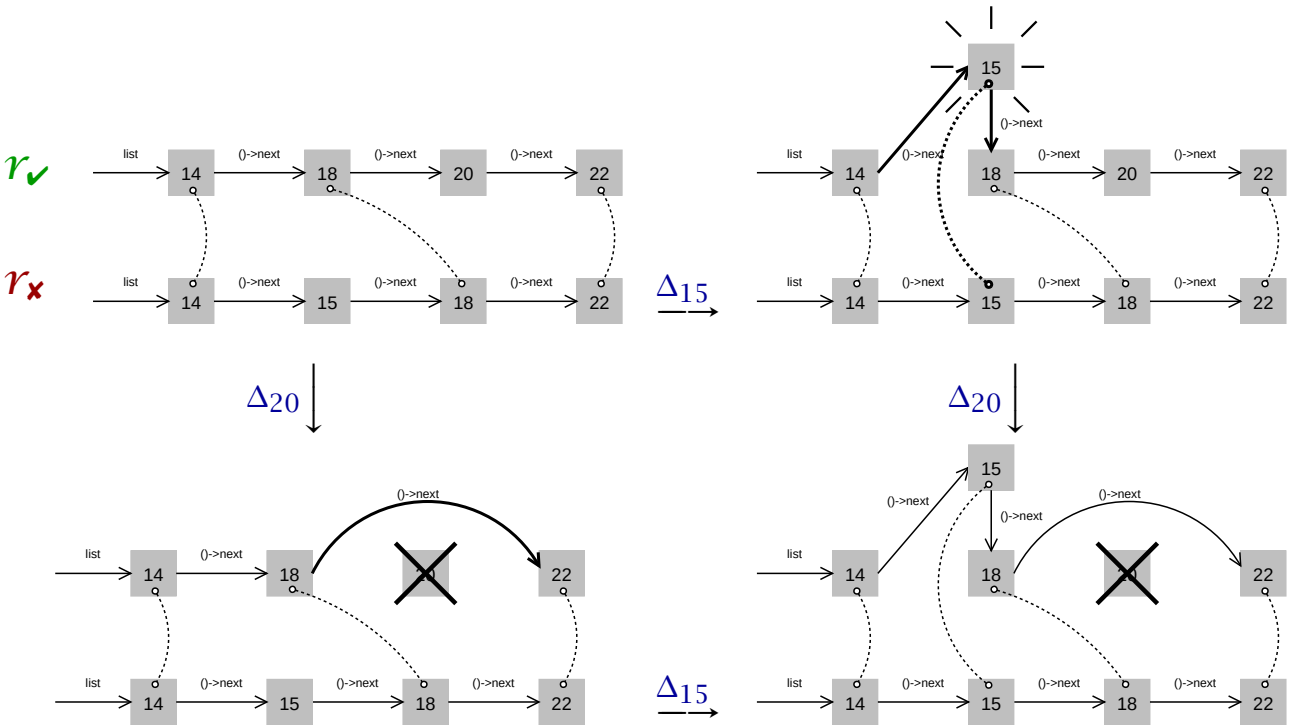

Das Verfahren in Kürze

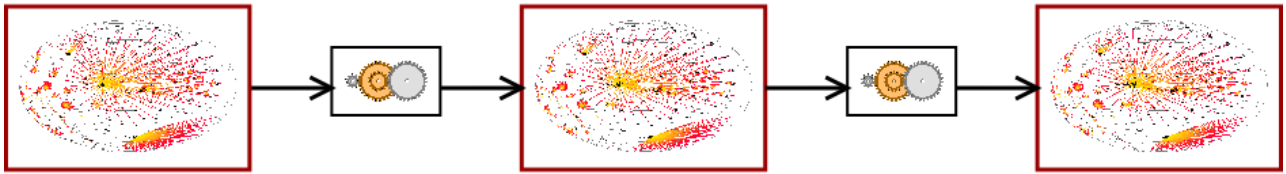

Failing Run

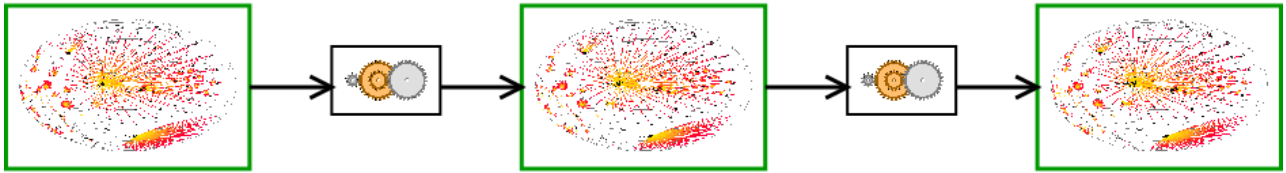

Passing Run

Das Verfahren in Kürze

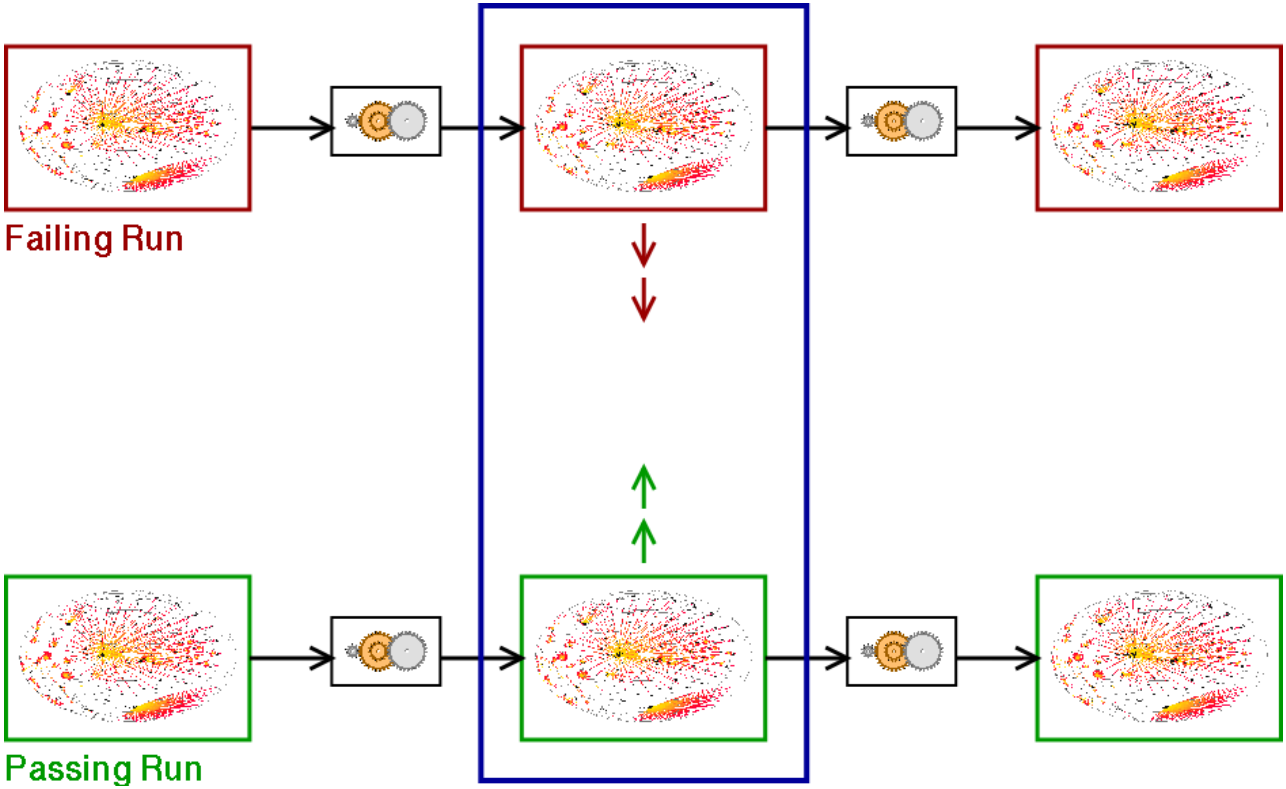

Das Verfahren in Kürze

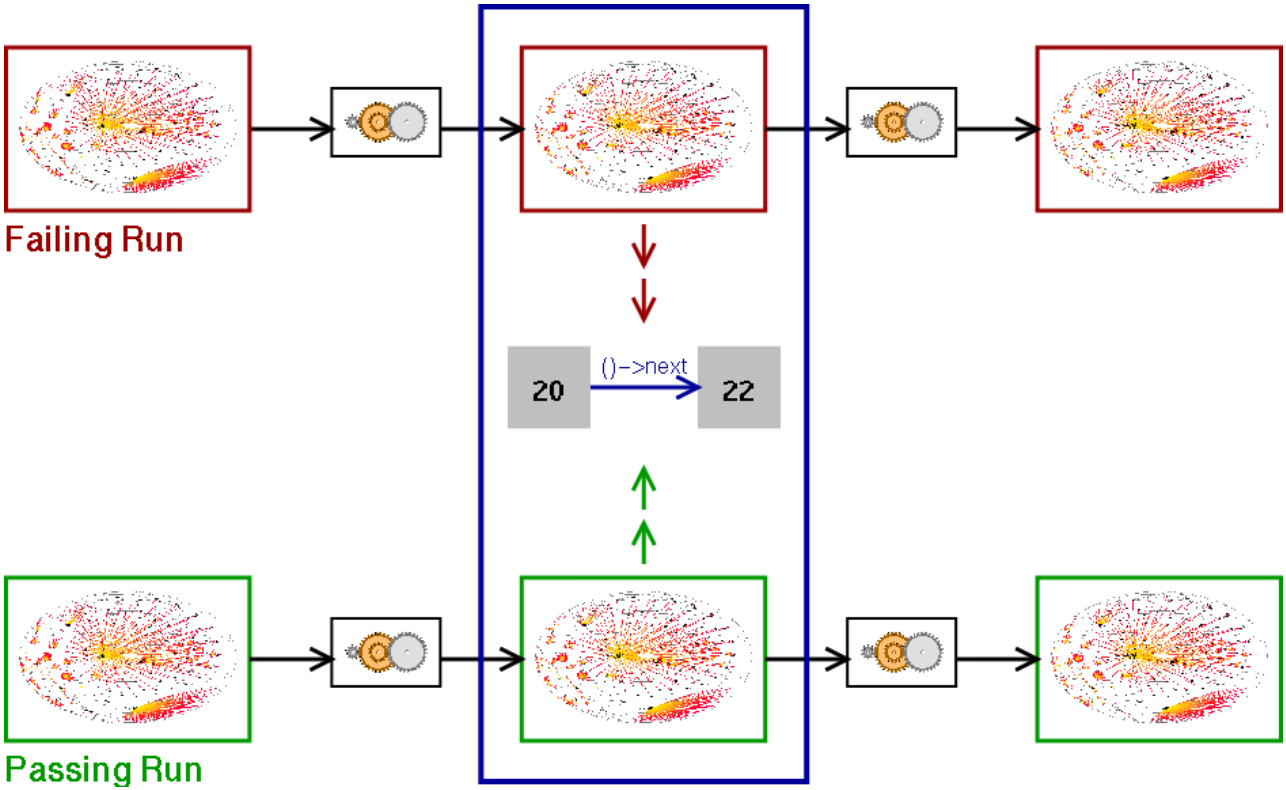

Relevante Zustandsunterschiede

IGOR untersucht den Zustand von cc1 in *combine_instructions*: 871 Knoten (= Variablen) sind unterschiedlich:

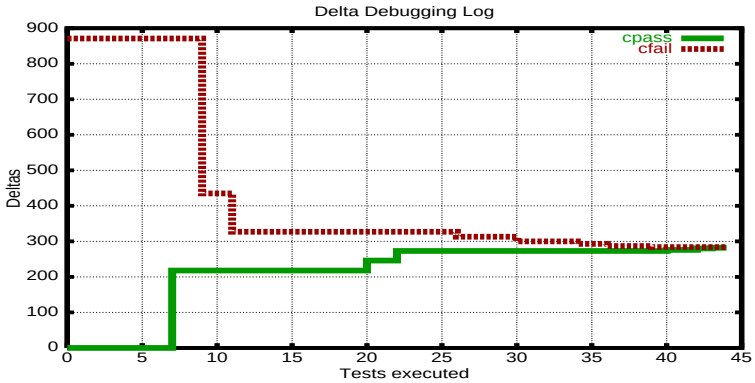

Nur eine Variable verursacht das Fehlschlagen:

```
$m = (struct rtx_def *)malloc(12)
$m->code = PLUS
first_loop_store_insn->fld[1]…rtx = $m
```

Die GCC Ursache-Wirkungs-Kette

Nach 59 Tests hat IGOR diese Fehlerursachen isoliert:

1. Execution reaches **main.**
   Since the program was invoked as "`cc1 -O fail.i`",
   variable **argv[2]** is now **"`fail.i`"**.

2. Execution reaches **combine_instructions.**
   Since argv[2] was "`fail.i`",
   variable ***first_loop_store_insn→fld[1].rtx→fld[1].rtx→fld[3].rtx→fld[1].rtx** is now ⟨**new rtx_def**⟩.

3. Execution reaches **if_then_else_cond (95th hit).**
   Since *first_loop_store_insn→fld[1].rtx→fld[1].rtx→fld[3].rtx→fld[1].rtx was ⟨new rtx_def⟩,
   variable **link→fld[0].rtx→fld[0].rtx** is now **link**.

4. Execution ends.
   Since variable link→fld[0].rtx→fld[0].rtx was link,
   the program now **terminates with a SIGSEGV signal**.
   The program fails.

Gesamt-Laufzeit: 6 Sekunden (+ 90 Minuten GDB-Overhead)

Fehler isolieren

Wir können den **Fehler** eingrenzen, indem wir (von Hand) **fehlerhafte** und **nicht-fehlerhafte** Ursachen unterscheiden.

Fehler isolieren

Wir können den **Fehler** eingrenzen, indem wir (von Hand) **fehlerhafte** und **nicht-fehlerhafte** Ursachen unterscheiden.

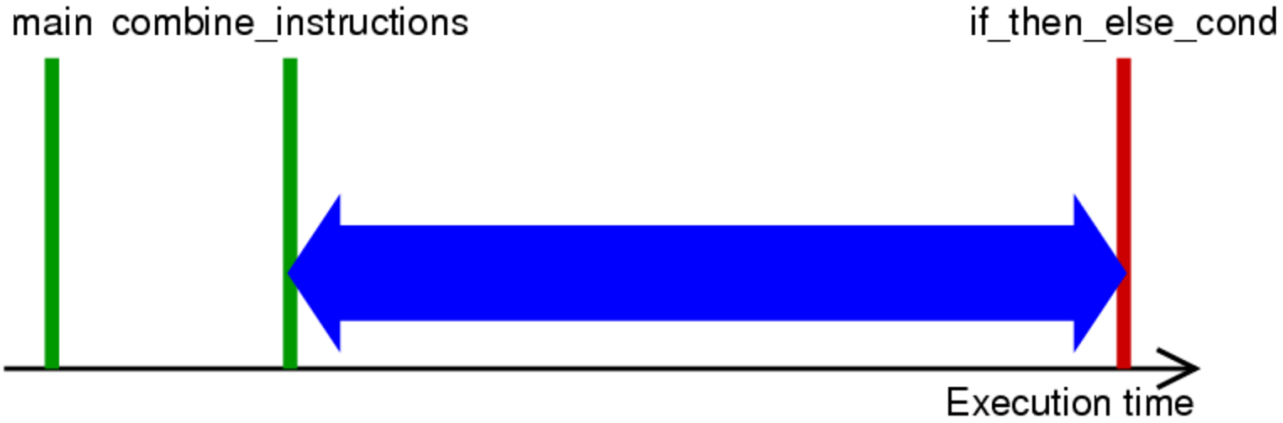

Fehler isolieren

Wir können den **Fehler** eingrenzen, indem wir (von Hand) **fehlerhafte** und **nicht-fehlerhafte** Ursachen unterscheiden.

Fehler isolieren

Wir können den **Fehler** eingrenzen, indem wir (von Hand) **fehlerhafte** und **nicht-fehlerhafte** Ursachen unterscheiden.

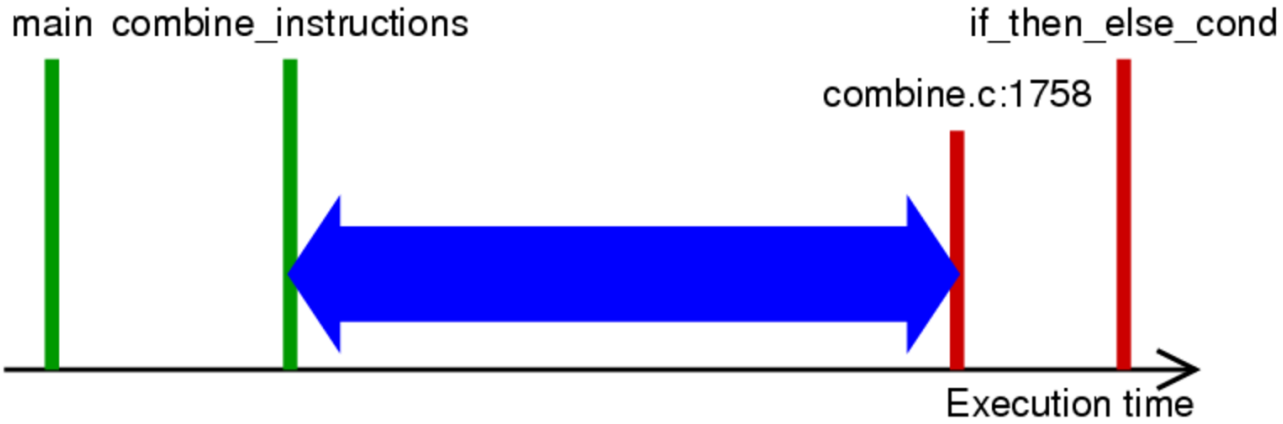

Fehler isolieren

Wir können den **Fehler** eingrenzen, indem wir (von Hand) **fehlerhafte** und **nicht-fehlerhafte** Ursachen unterscheiden.

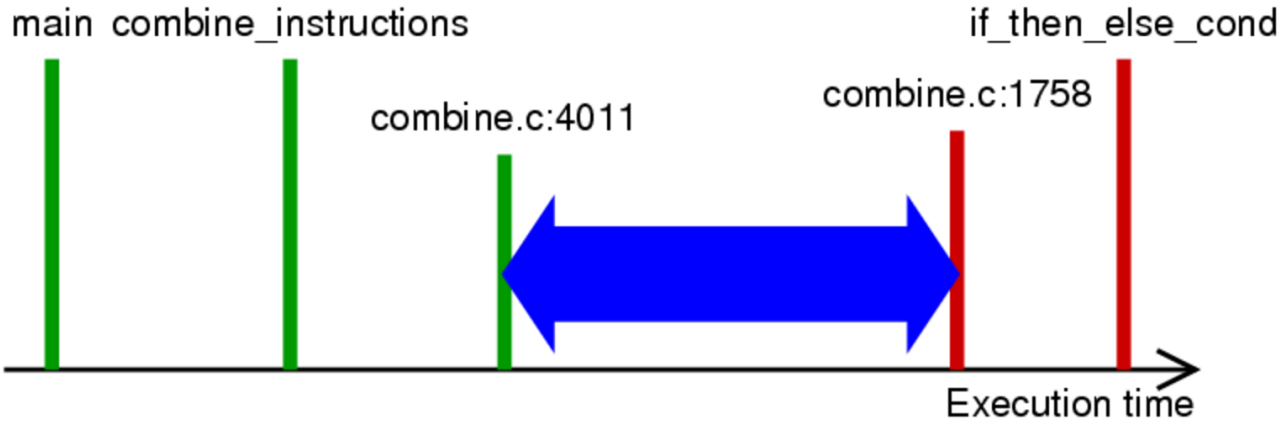

Fehler isolieren

Wir können den **Fehler** eingrenzen, indem wir (von Hand) **fehlerhafte** und **nicht-fehlerhafte** Ursachen unterscheiden.

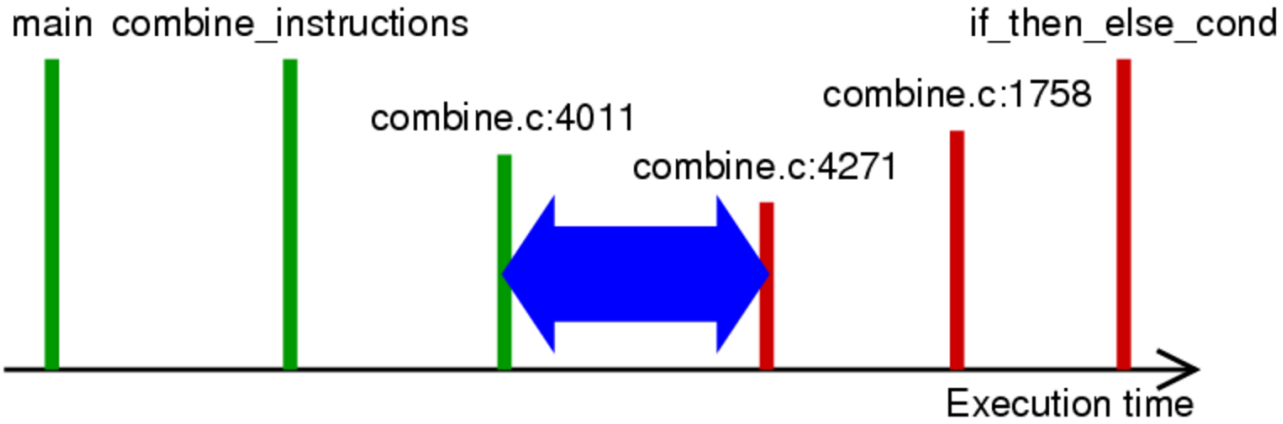

Falsches Alias im Distributivgesetz in Zeilen 4013–4019; behoben in 2.95.3

$(+\ (*\ a\ b)\ c) \Rightarrow (*\ (+\ a\ c_1)(+\ b\ c_2))$ with $c = c_1 = c_2$

Herausforderungen

Wie finden wir relevante Ereignisse?

Warum z.B. bei combine_instructions suchen?

Heute: Suchen im *Backtrace* des fehlschlagenden Laufes

Morgen: Fokus auf *Ursachen-Übergänge*.

Wie erfassen wir C-Zustände akkurat?

Zeigt p auf etwas, und wenn ja, wieviele?

Heute: Anfragen an das Laufzeitsystem + Heuristiken.

Morgen: Wechsel zu Java :-)

Woher wissen wir, dass ein Fehlschlag der Fehlschlag ist?

Können Änderungen nicht neue Fehlschläge bewirken?

Heute: Backtraces müssen übereinstimmen.

Morgen: Ausgabe, Zeit, Code-Abdeckung vergleichen.

Und schließlich: *Wann funktioniert dies eigentlich?*

www.askigor.org

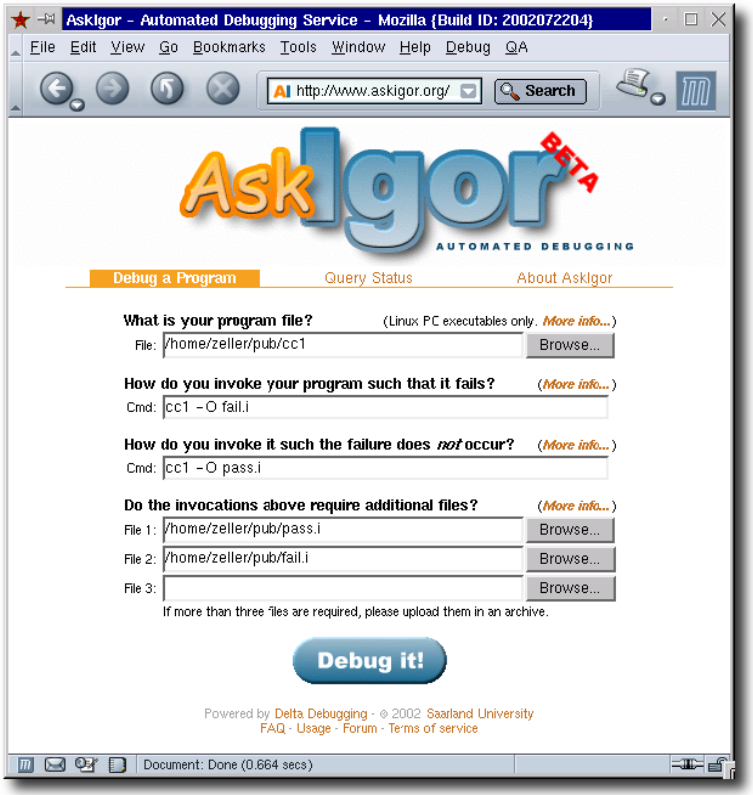

Programm einreichen

⇓

Aufrufe angeben

⇓

Auf „Debug it“ klicken

⇓

Diagnose per e-mail

600 Einreichungen
seit Dezember 2003

.

56% „pinpoints the bug“
22% „helpful insights“

.

Open Source!

Delta Debugging Plug-Ins

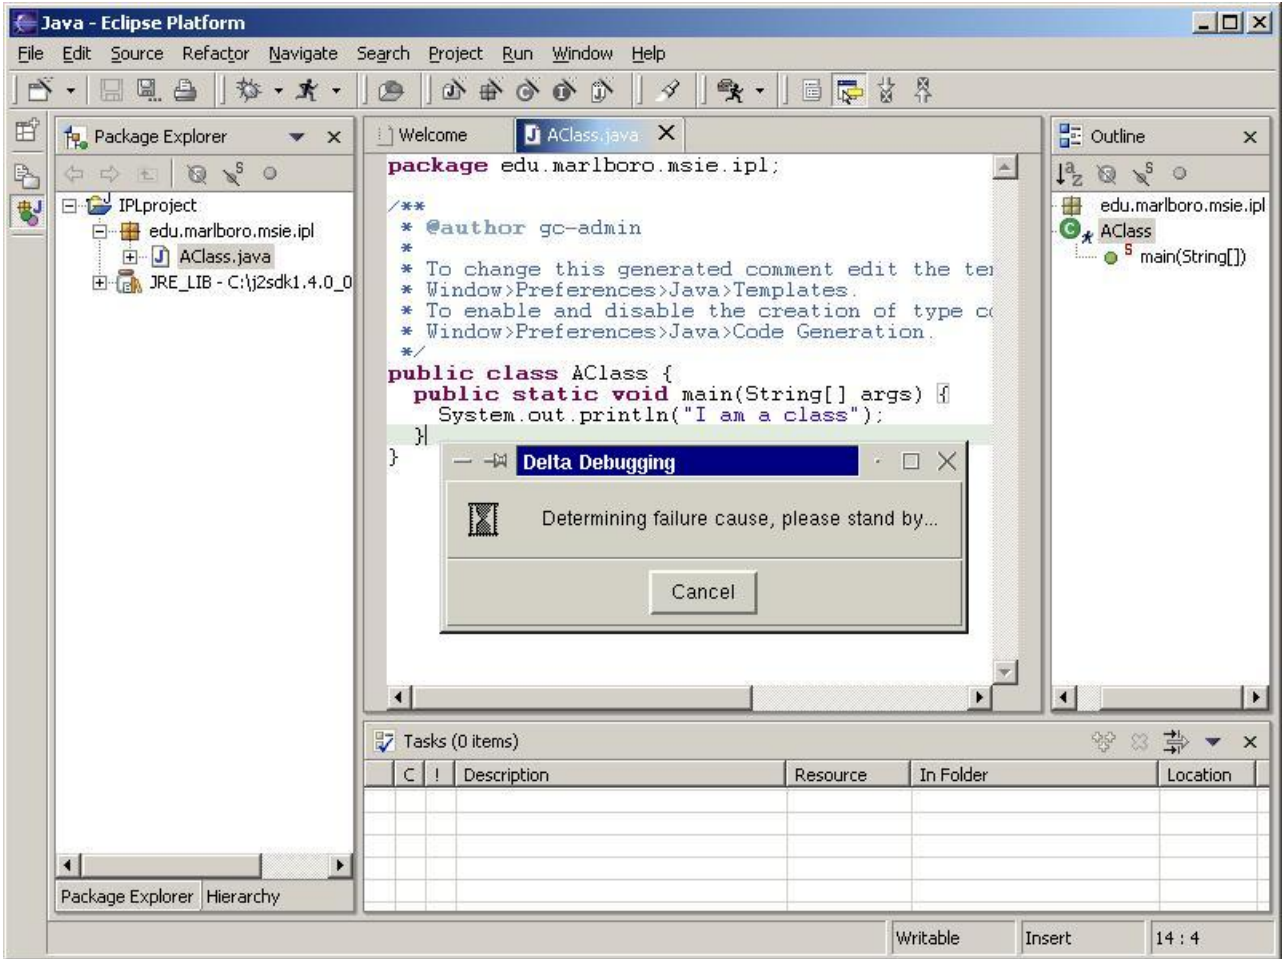

Delta Debugging in einem Lauf

In einem reaktiven Programm kann ein Lauf genügen:

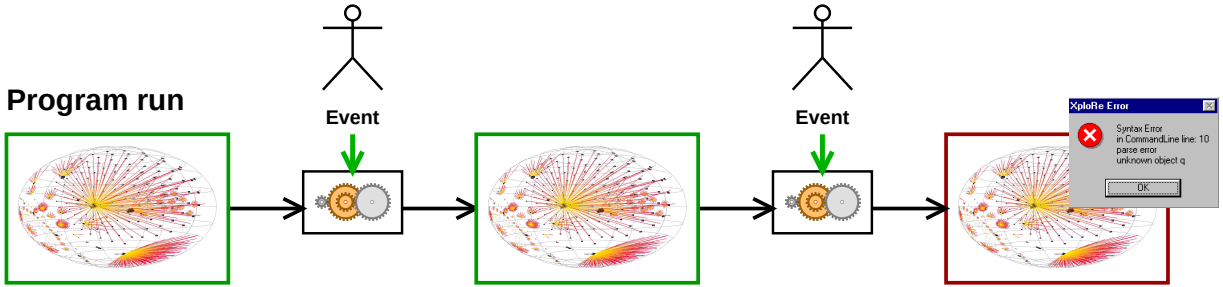

Delta Debugging in einem Lauf

In einem reaktiven Programm kann ein Lauf genügen:

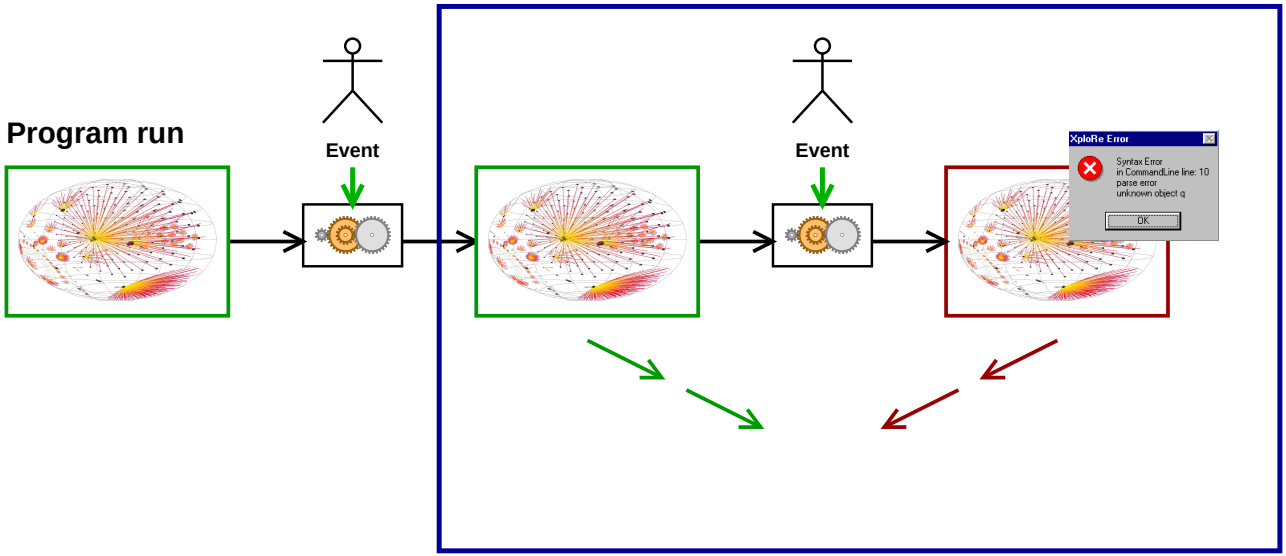

Vergleich der Zustände *zu verschiedenen Zeitpunkten* zeigt Unterschiede…

Delta Debugging in einem Lauf

In einem reaktiven Programm kann ein Lauf genügen:

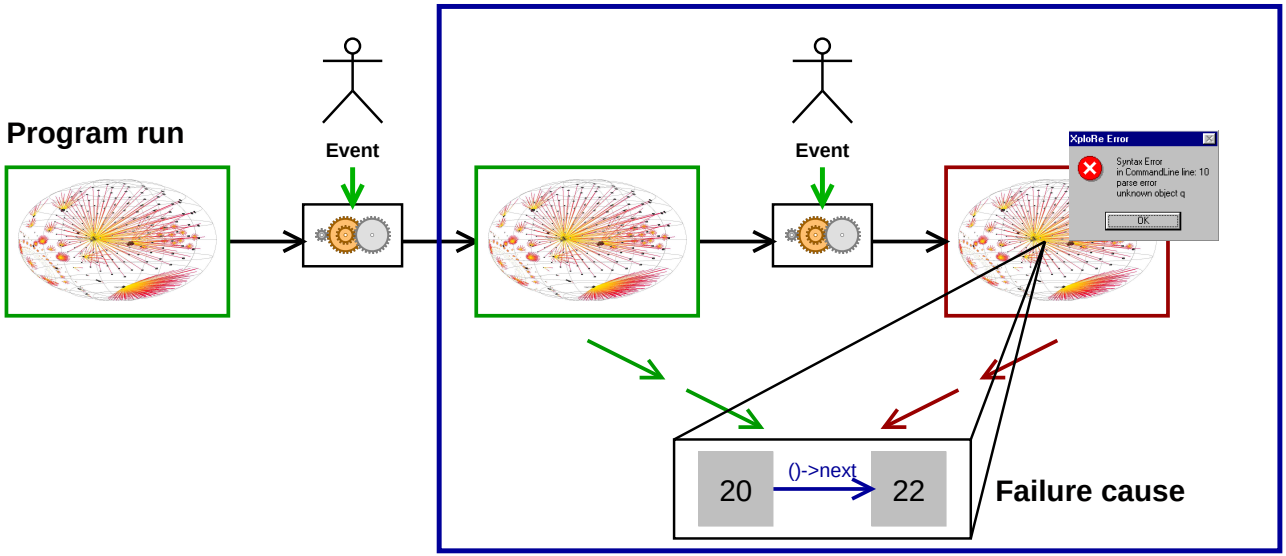

Vergleich der Zustände *zu verschiedenen Zeitpunkten* zeigt Unterschiede, die zu Ursachen eingeengt werden können.

Anwendungen: interaktive Programme, Server, Treiber…

Selbstheilende Programme

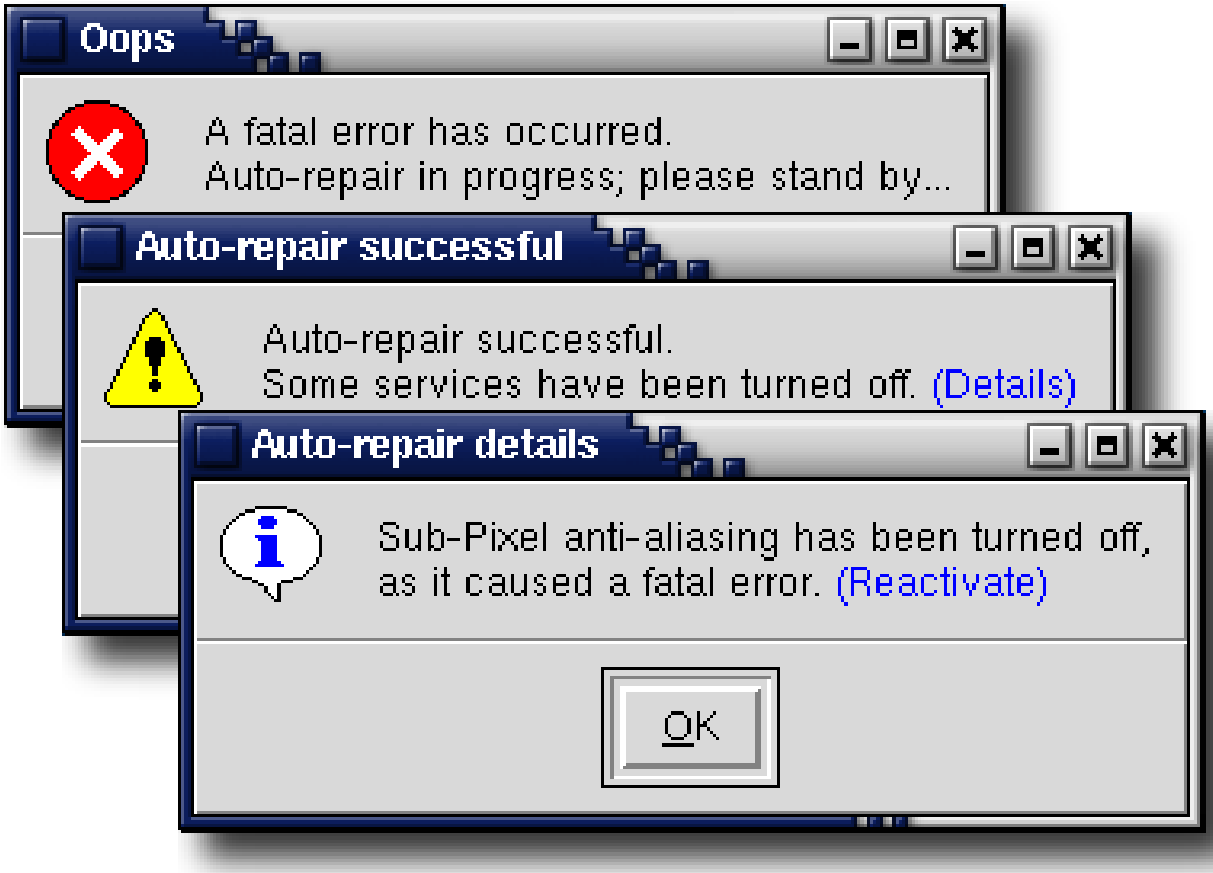

Rückblick und Ausblick

Letzte 20 Jahre: *Deduktion* und *Observations*- Techniken

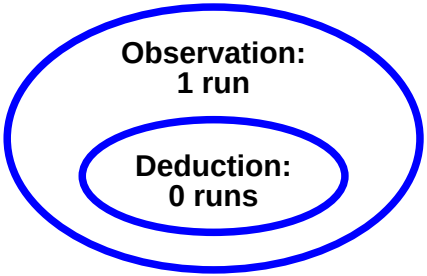

Rückblick und Ausblick

Letzte 20 Jahre: *Deduktion* und *Observations*- Techniken

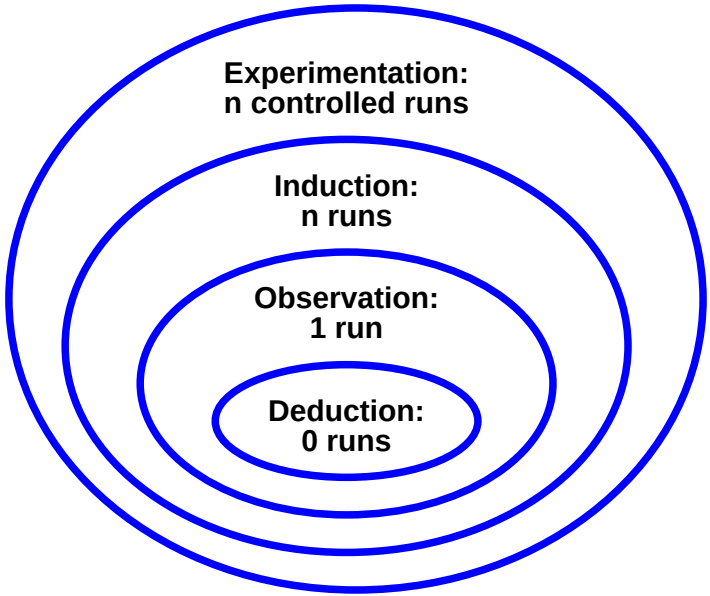

Nächste 20 Jahre: *Induktion* und *Experimentieren?*

Fazit

- ★ Wir können die Abwesenheit von Fehlern beweisen – doch nie die *Abwesenheit von Überraschungen.*
- ★ Fehlerursachen können *automatisch isoliert werden*…
  - mit Hilfe eines automatischen Tests
  - in dem wenigstens ein Testfall erfolgreich ist
- ★ Systematisches *Experimentieren* kann „klassische“ Programm-Analyse erheblich verbessern.
- ★ Durch Automatisierung wird Fehlersuche zu einer *verstandenen und systematischen Disziplin.*
- ★ Buch „Why does my program fail?“ (MK) im Mai 2005

http://www.askigor.org/







Zum Weiterlesen

Why does my Program Fail? A Guide to Automated Debugging. Morgan Kaufmann Publishers, Spring 2005.

Isolating Cause-Effect Chains from Computer Programs. Proc. ACM SIGSOFT International Symposium on the Foundations of Software Engineering (FSE 2002), Charleston, Nov. 2002.

Isolating Failure-Inducing Thread Schedules. (w/ J.-D. Choi) Proc. ACM SIGSOFT International Symposium on Software Testing and Analysis (ISSTA 2002), Rom, July 2002.

Simplifying and Isolating Failure-Inducing Input. (w/ R. Hildebrandt) IEEE Transactions on Software Engineering 28(2), February 2002, pp. 183–200.

Automated Debugging: Are We Close? IEEE Computer, Nov. 2001, pp. 26–31.

Visualizing Memory Graphs. (w/ T. Zimmermann) Proc. of the Dagstuhl Seminar 01211 „Software Visualization“, May 2001. LNCS 2269, pp. 191–204.

Yesterday, my program worked. Today, it does not. Why? Proc. ACM SIGSOFT Conference (ESEC/FSE 1999), Toulouse, Sep. 1999, LNCS 1687, pp. 253–267.

http://www.askigor.org/

About this Presentation

This presentation was created by Andreas Zeller, Professor of Computer Science at Saarland University, Saarbrücken, Germany. Contact him at

http://www.st.cs.uni-sb.de/~zeller/

This presentation, its source code, and additional material can be downloaded at

http://www.st.cs.uni-sb.de/papers/fse2002/