Verlässliche Echtzeitsysteme

Testen

Fabian Scheler

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

`www4.informatik.uni-erlangen.de`

25. April 2012

Gliederung

Warum testet man eigentlich?

- Ziel: Aussage zu nicht-funktionalen Eigenschaften von Software
  - in dieser Vorlesung: Korrektheit (oder zumindest: Absenz von Defekten)
    - dieser wiederum kann man sich über die Qualität oder dem Verhalten nähern
- Hierfür gibt es verschiedene Möglichkeiten:
  - informelle Methoden
    - Inspection, Review, Walkthrough, ...
  - analytische Methoden
    - Metriken, Kodierrichtlinien, ...
  - formale Methoden
    - Model Checking, Theorembeweiser, ...
  - dynamisches Testen
    - Black-Box, White-Box, Regression, Unit, ...

  } Aussagen über die Qualität

  } Aussagen über die Verhalten

- in dieser Vorlesung steht das Verhalten im Vordergrund

  $\rightsquigarrow$ man führt das Programm „einfach“ aus $\rightsquigarrow$ Testen
  - formale Methoden erfüllen prinzipiell denselben Zweck
    - ihre Handhabung ist aber noch beschränkt, ohne Tests kommt man nicht aus

Tests haben Grenzen!

- Tests eignen sich nicht für einen Korrektheitsnachweis!
  - „. . . wir haben schon lange keinen Fehler mehr gefunden . . . “
    - einer Auffassung der man oft begegnet
    - ⇝ der entscheidende Fehler kann sich immer noch versteckt halten
  - der Therac 25 (s. Folie II/4 ff.) wurde $>$ 2700 Stunden betrieben
    - ohne dass ein „nennenswerter“ Fehler aufgetreten wäre
    - trotzdem kam es zu den verheerenden Vorfällen
- Testen kann nur das Vertrauen in Stück Software erhöhen!
- Tests sind sehr aufwändig!
  - Woher weiß man, dass man genügend getestet hat?

Gliederung

Einordnung in den Entwicklungsprozess

Softwareentwicklung nach dem V-Modell wird zugrunde gelegt

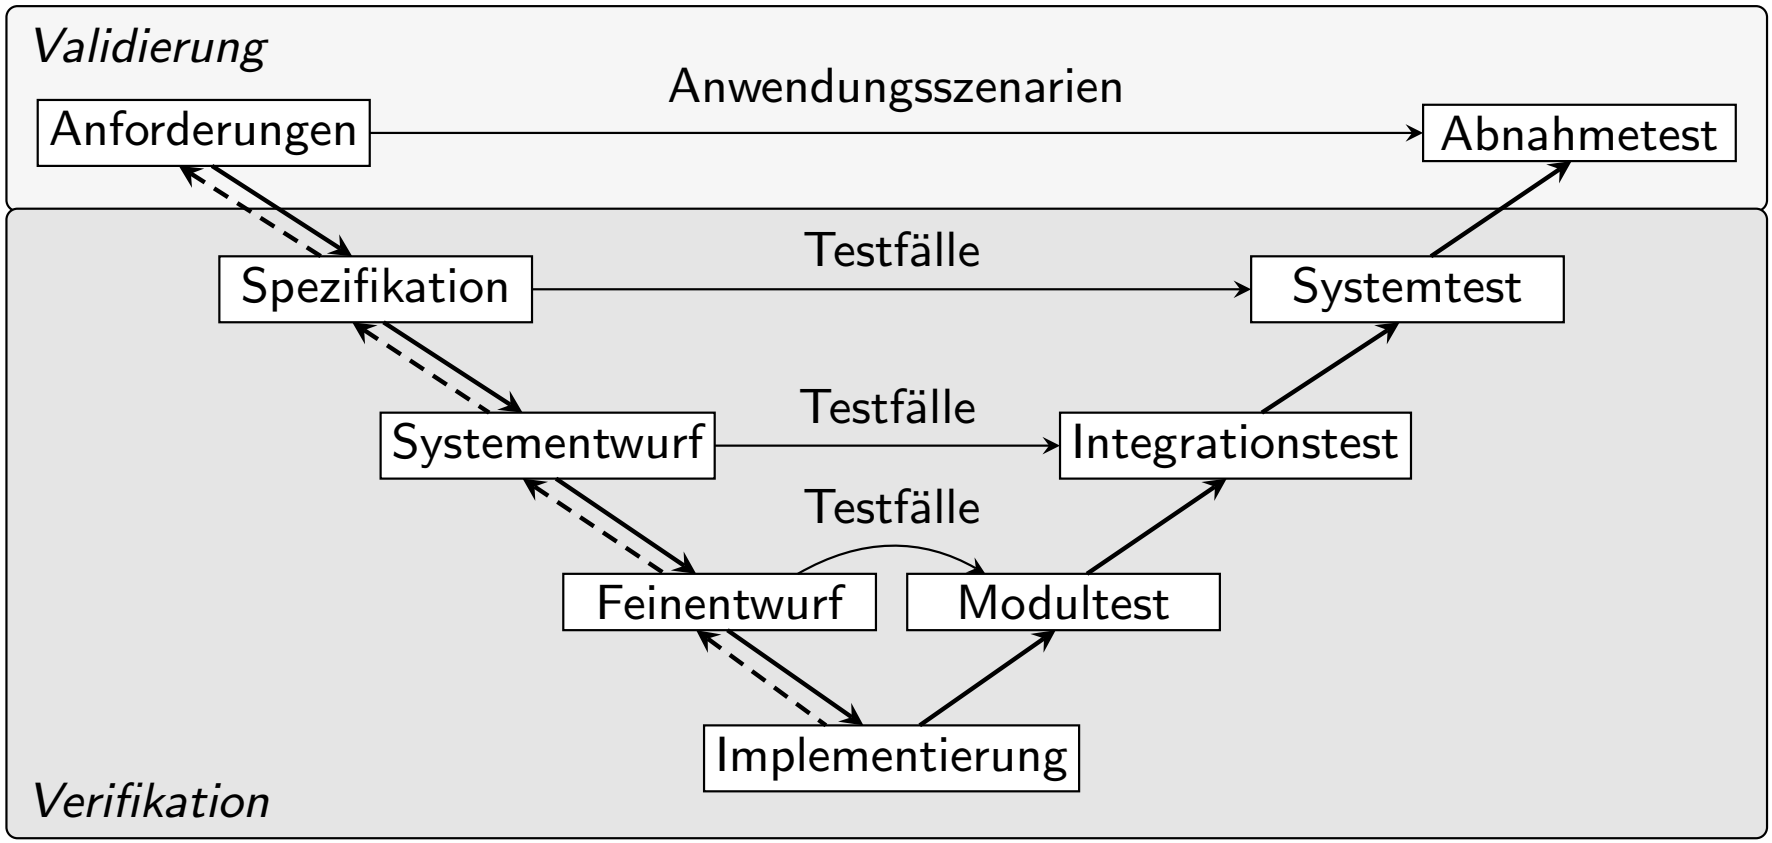

- weit verbreitetes Vorgehensmodell für die Softwarenentwicklung
  - absteigender Ast $\rightsquigarrow$ Sezifikation, Entwurf, Implementierung
  - aufsteigender Ast $\rightsquigarrow$ Verifikation & Validierung
  - Querbeziehungen $\rightsquigarrow$ Testfallableitung

Tests in den verschiedenen Phasen des V-Modells

Modultest (engl. *unit testing*)

- Diskrepanz zwischen Implementierung und Entwurf/Spezifikation

Integrationstest (engl. *integration testing*)

- Probleme beim Zusammenspiel mehrere Module

Systemtest (engl. *system testing*)

- Black-Box-Test auf Systemebene
- Vergleich: geforderte Leistung $\leftrightarrow$ tatsächliche Leistung
  - funktional: sind alle Merkmale verfügbar
  - nicht-funktional: wird z.B. ein bestimmter Durchsatz erreicht

Abnahmetest (engl. *acceptance testing*)

- erfüllt das Produkt die Anforderungen des Auftraggebers
- Korrektheit, Robustheit, Performanz, Dokumentation, ...
- wird durch Anwendungsszenarien demonstriert/überprüft
  - hier findet also eine Validierung statt, keine Verifikation

Fokus der heutigen Vorlesung

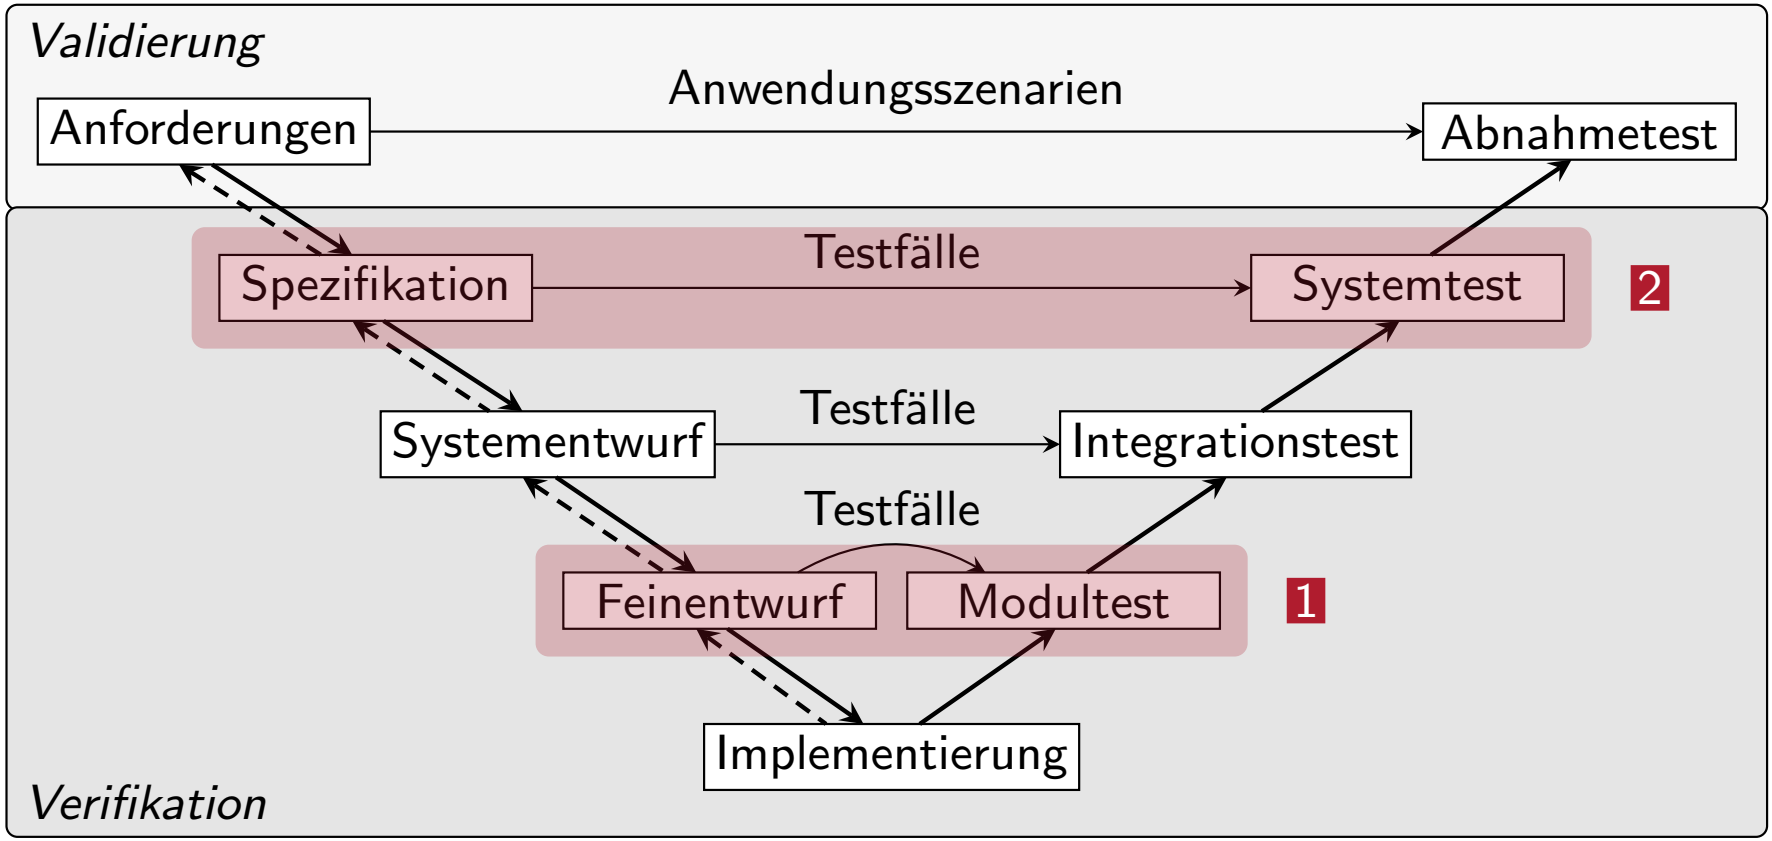

1. Modultests ⇝ Grundbegriffe und Problemstellung
   - ⇝ Black- vs. White-Box, Testüberdeckung
2. Systemtest ⇝ Testen verteilter Echtzeitsysteme
   - ⇝ Problemstellung und Herausforderungen

Gliederung

Eigenschaften von Modultests

- Modultests beziehen sich auf kleine Softwareeinheiten
  - meist auf Ebene einzelner Funktionen
    - die Testbarkeit ist zu gewährleisten $\rightsquigarrow$ Begrenzung der notwendigen Testfälle
- Modultests erfolgen in Isolation
  - für den (Miss-)Erfolg ist nur das getestete Modul verantwortlich
  - andere Module werden durch Attrappen (engl. *mock-objects*) ersetzt
- Modultests werden fortlaufend durchgeführt
  - jede Änderung am Quelltext sollte auf ihre Verträglichkeit geprüft werden

  $\rightsquigarrow$ Regressionstests (engl. *regression testing*) $\rightsquigarrow$ Automatisierung notwendig
- Modultests sollten auch den Fehlerfall prüfen
  - es genügt nicht zu Prüfen, dass das Ergebnis korrekt berechnet wird

  $\rightsquigarrow$ der Fehlerfall (Eingaben, Zustand, ...) soll einbezogen werden
- Modultest betrachten die Schnittstelle
  - Anwendung des Design-By-Contract-Prinzips $\rightsquigarrow$ Black-Box-Tests
  - interne Details ($\rightsquigarrow$ White-Box-Tests) führen zu fragilen Testfällen

Black-Box- vs. White-Box-Tests

- Black-Box-Tests
  - keine Kenntnis der internen Struktur
  - Testfälle basieren ausschließlich auf der Spezifikation
  - Synonyme: funktionale, datengetriebene, E/A-getriebene Tests

☞ **Frage:** Wurden alle Anforderungen implementiert?

- White-Box-Tests
  - Kenntnis der internen Struktur zwingend erforderlich
  - Testfälle basieren auf Programmstruktur, Spezifikation wird ignoriert
  - Synonyme: strukturelle, pfadgetriebene, logikgetriebene Tests

☞ **Frage:** Wurden nur Anforderungen implementiert?

☞ weiterer Verlauf der Vorlesung: Fokus auf White-Box-Verfahren
  - abstrakte Interpretation, Model Checking, Coverage, WP-Kalkül, ...

Problem: Kombinatorische Explosion

Komplett ohne Einsicht in die Programmstruktur ist Testen sehr mühsam!

- Beispiel: Modultests für OSEK OS [2]
  - verschiedene Betriebssystemdienste
    - Fadenverwaltung, Fadensynchronisation, Nachrichtenkommunikation, ...
  - hohe Variabilität
    - **4** Konformitätsklassen: BCC1, BCC2, BCC3, BCC4
    - **3** Varianten der Ablaufplanung: NON, MIXED, FULL
    - **2** Betriebsmodi: Betrieb (STANDARD), Entwicklung (EXTENDED)

  $\rightsquigarrow$ 24 Varianten für jeden Testfall
- Black-Box $\rightsquigarrow$ kein Wissen über die interne Struktur nutzbar
  - konservative Annahme: Parameter beeinflussen sich gegenseitig

  $\rightsquigarrow$ alle Kombinationen sind relevant: **Kombinatorische Explosion!**
- Kombination aus Black- und White-Box-Tests

  $\rightsquigarrow$ Unabhängigkeit der Parameter kann evtl. sichergestellt werden

  $\rightsquigarrow$ Reduktion der Testfälle bzw. deren Varianten

Hat man genug getestet?

- Kriterium: Anzahl der Testfälle
  - basierend auf Metriken
    - McCabe's Cyclomatic Complexity (MCC), Function/Function Points, ...
  - mithilfe von Statistiken aus früheren Projekten
    - Kennzahlen früherer Projekte $\leadsto$ Anzahl zu erwartender Defekte
    - Wie viele Defekte hat man bereits gefunden, wie viele sind noch im Produkt?
    - Wie viele Defekte will/kann man ausliefern?
- Kriterium: Testüberdeckung
  - Welcher Anteil des Systems wurde abgetestet?
    - Wurden ausreichend viele Programmpfade absolviert?
    - Wurden alle Variablen, die definiert wurden, auch verwendet?

McCabe's Cyclomatic Complexity [1, Kapitel 8.1]

- Maß für die Anzahl der unabhängigen Pfade durch ein Programm

  ⇝ je höher die MCC, desto höher die Komplexität
- Berechnung basiert auf dem Kontrollflussgraphen
  - Knoten repräsentieren Anweisungen, Kanten Pfade

  ⇝ Komplexität C:

$$C = e - n + 2$$

  - $e \mathrel{\widehat{=}}$ Anzahl der Kanten, $n \mathrel{\widehat{=}}$ Anzahl der Knoten
- Beispiele:

Sequenz

C = 1

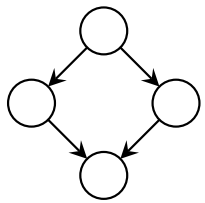

Verzweigung

C = 2

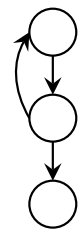

Do-While

C = 2

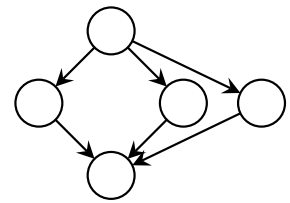

Fallunterscheidung

C = 3

- ☞ Untere Schranke für die Anzahl der Testfälle!
  - in der Praxis gilt ein Wert im Bereich 1 - 10 als akzeptabel

Grundlegende Überdeckunskriterien

Wie sehr wurde ein Modul durch Tests beansprucht?

$C_0 = s/S$ Anweisungsübderdeckung (engl. *statement coverage*)

- $s \rightsquigarrow$ erreichte Anweisungen, $S \rightsquigarrow$ alle Anweisungen
- findet nicht erreichbaren/getesteten/übersetzten Code
- Nachteile:
  - Gleichgewichtung aller Anweisungen
  - keine Berücksichtigung leerer Pfade oder Datenabhängigkeiten

$C_1 = b/B$ Zweigüberdeckung (engl. *branch coverage*)

- $b \rightsquigarrow$ ausgeführte primitive Zweige, $B \rightsquigarrow$ alle primitiven Zweige
  - Verzweigungen hängen u.U. voneinander ab

$\rightsquigarrow$ Zweigüberdeckung und dafür benötigte Testfälle sind nicht proportional

$\rightsquigarrow$ primitive Zweige sind unabhängig von anderen Zweigen

- findet nicht erreichbare Zweige, Defekterkennungsrate ca. 33%
- Nachteile: unzureichende Behandlung
  - abhängiger Verzweigungen
  - von Schleifen $\rightsquigarrow$ Pfadüberdeckung
  - komplexer Verzweigungsbedingungen $\rightsquigarrow$ Bedingungsüberdeckung

Beispiel: Anweisungs- und Zweigüberdeckung

```
int foo(int a,int b,int c) {
  if((a > b && a > c) || c < 0) {
    if(a < b) return 1;
    else {
      if(b < c) return 2;
    }
  }
  return 4;
}
```

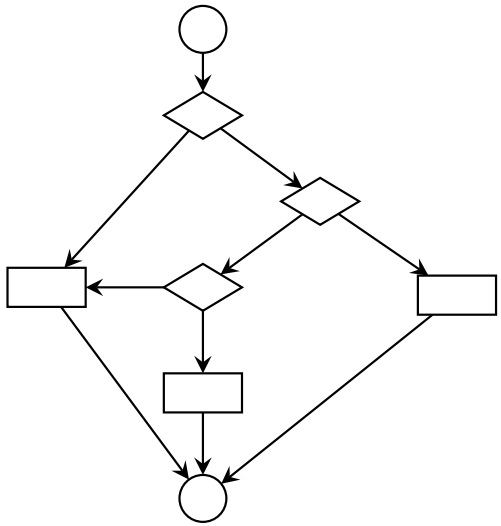

- Anweisungsüberdeckung
  - Test 1: `foo(0,0,0)`
  - Test 2: `foo(0,1,-1)`
  - Test 3: `foo(2,0,1)`
- Zweigüberdeckung
  - Test 1: `foo(0,0,0)`
  - Test 2: `foo(0,1,-1)`
  - Test 3: `foo(2,0,1)`
  - Test 4: `foo(2,1,1)`
- 100% Zweigüberdeckung $\mapsto$ 100% Anweisungsüberdeckung
- Zweigüberdeckung: weite industrielle Verbreitung
  - moderater Aufwand, gute Defekterkennungsrate

Pfadüberdeckung

C_2 = p/P Pfadüberdeckung (engl. *path coverage*)

- Pfade vom Anfangs- bis zum Endknoten im Kontrollflussgraphen
- Abstufungen der Pfadüberdeckung

  C_2a vollständige Pfadüberdeckung
  - Abdeckung aller möglichen Pfade
  - Problem: durch Schleifen entstehen u. U. unendlich viele Pfade

  C_2b Boundary-Interior Pfadüberdeckung
  - wie C_2a, Anzahl der Schleifendurchläufe wird auf ≤ 2 beschränkt

  C_2c strukturierte Pfadüberdeckung
  - wie C_2b, Anzahl der Schleifendurchläufe wird auf $\leq n$ beschränkt
- Bedeutung Boundary-Interior

  boundary – jede Schleife wird 0-mal betreten

  – jede Schleife wird betreten, alle Pfade im Rumpf abgearbeitet

  interior – Beschränkung: mit 2/n Durchläufen erreichbare Pfade im Rumpf
- hohe Defekterkennungsrate
- bestimmte Pfade können nicht erreicht werden, hoher Aufwand

Bedingungsüberdeckung

C_3 Bedingungsüberdeckung (engl. *condition coverage*)

- $C_{0,1,2}$: unzureichende Betrachtung von Bedingungen
  - ihr Zusammensetzung/Hierarchie wird nicht berücksichtigt
- Abstufungen der Bedingungsüberdeckung

  ### C_3a Einfachbedingungsüberdeckung
  - jede atomare Bedingung wird einmal mit `true` und `false` getestet

  ### C_3b Mehrfachbedingungsüberdeckung
  - alle Kombinationen atomarer Bedingungen werden getestet

  ### C_3c minimale Mehrfachbedingungsüberdeckung
  - jede atomare/komplexe Bedingung wird einmal mit `true` und `false` getestet

  ### MC/DC (engl. *modified condition/decision coverage*)
  - Sonderform der C_3c-Überdeckung
  - jede atomare Bedingung wird mit `true` und `false` getestet und ...
  - muss zusätzlich die umgebende komplexe Bedingung beeinflussen
- sehr hohe Fehlererkennungsrate
- bestimmte Pfade können nicht erreicht werden, hoher Aufwand

Beispiel: Bedingungsüberdeckung

```
int foo(int a,int b,int c) {
  if((a > b && a > c) || c < 0) {
    if(a < b) return 1;
    else {
      if(b < c) return 2;
    }
  }
  return 4;
}
```

- Fokus auf die Bedingung:
  `(a > b && a > c) || c < 0`
  - 3 atomare Teilbedingungen
    - `a > b`
    - `a > c`
    - `c < 0`

- Einfachbedingungeüberdeckung

a > b	a > c	c < 0	Testfall
w	w	w	f(1,0,-1)
f	f	f	f(0,1,1)

- Modified Condition/Decision Coverage

a > b	a > c	c < 0	(a > b && a > c) || c < 0	Testfall
w	**w**	f	w	f(1,0,0)
f	w	**f**	f	f(1,1,0)
w	**f**	**f**	f	f(1,0,1)
f	f	**w**	w	f(-1,0,-1)

Gliederung

Herausforderungen beim Testen verteilter EZS [3]

Erwachsen vor allem aus der Betrachtung auf Systemebene

- Herausforderungen spezifisch für Echtzeitsysteme
  - starke Kopplung zur Umgebung
    - Echtzeitsysteme interagieren vielfältig mit dem kontrollierten Objekt
  - Voranschreiten der realen Zeit nicht vernachlässigbar
    - physikalische Vorgänge im kontrollierten Objekt sind an die Zeit gekoppelt
  - Umgebung kann nicht beliebig beeinflusst werden
    - Kontrollbereich der Aktuatoren ist beschränkt
- Herausforderungen spezifisch für verteilte Systeme
  - hohe Komplexität
    - Verteilung erhöht Komplexität $\leadsto$ Allokation, Kommunikation, ...
  - Beobachtung und Reproduzierbarkeit des Systemverhaltens
  - fehlende globale Zeit $\leadsto$ kein eindeutiger globaler Zustand
    - globale, konsistente Abbilder sind ein großes Problem

Problemfeld: Testen verteilter Echtzeitsysteme

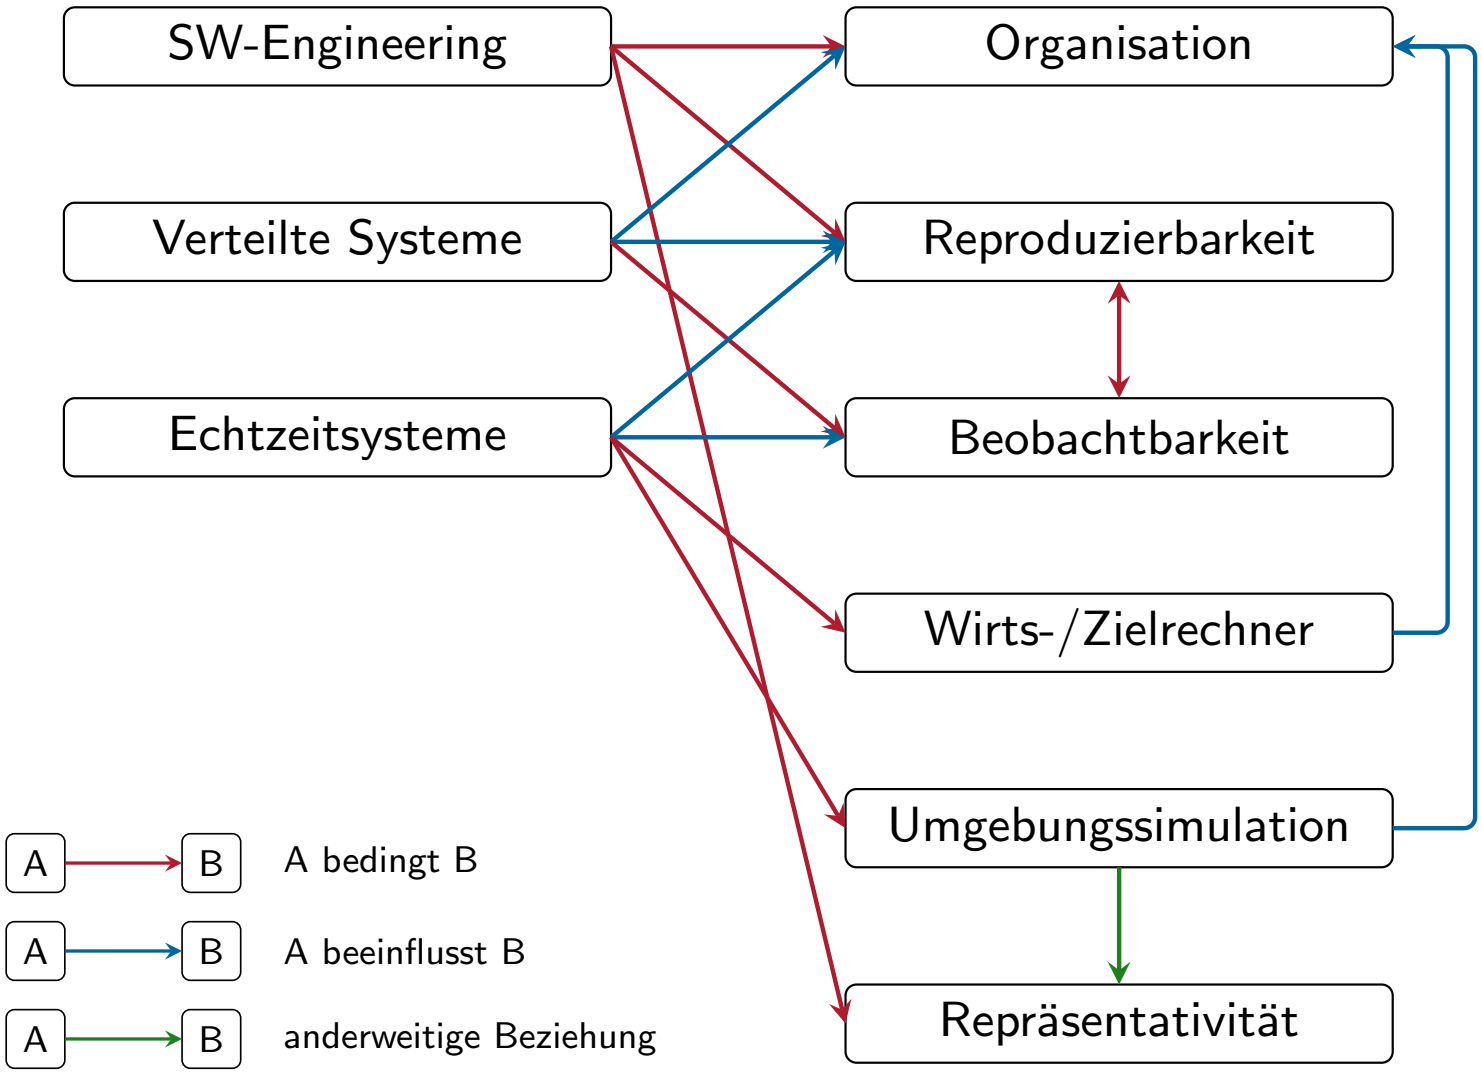

Problemfeld: Fokus „SW-Engineering“

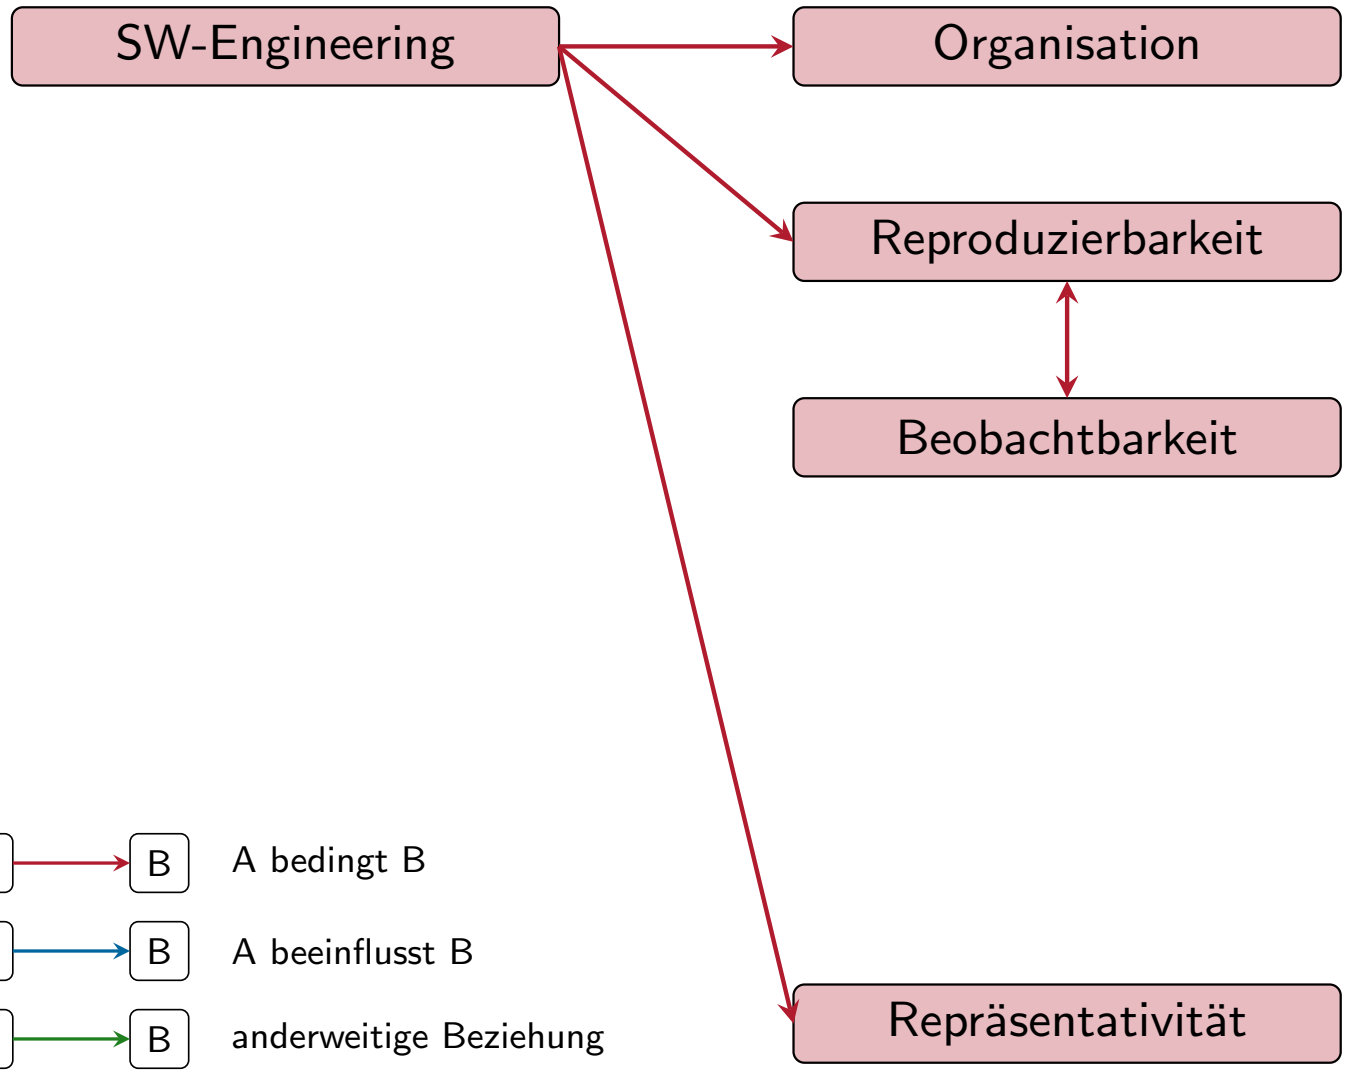

Problemfeld: Fokus „Verteilte Systeme“

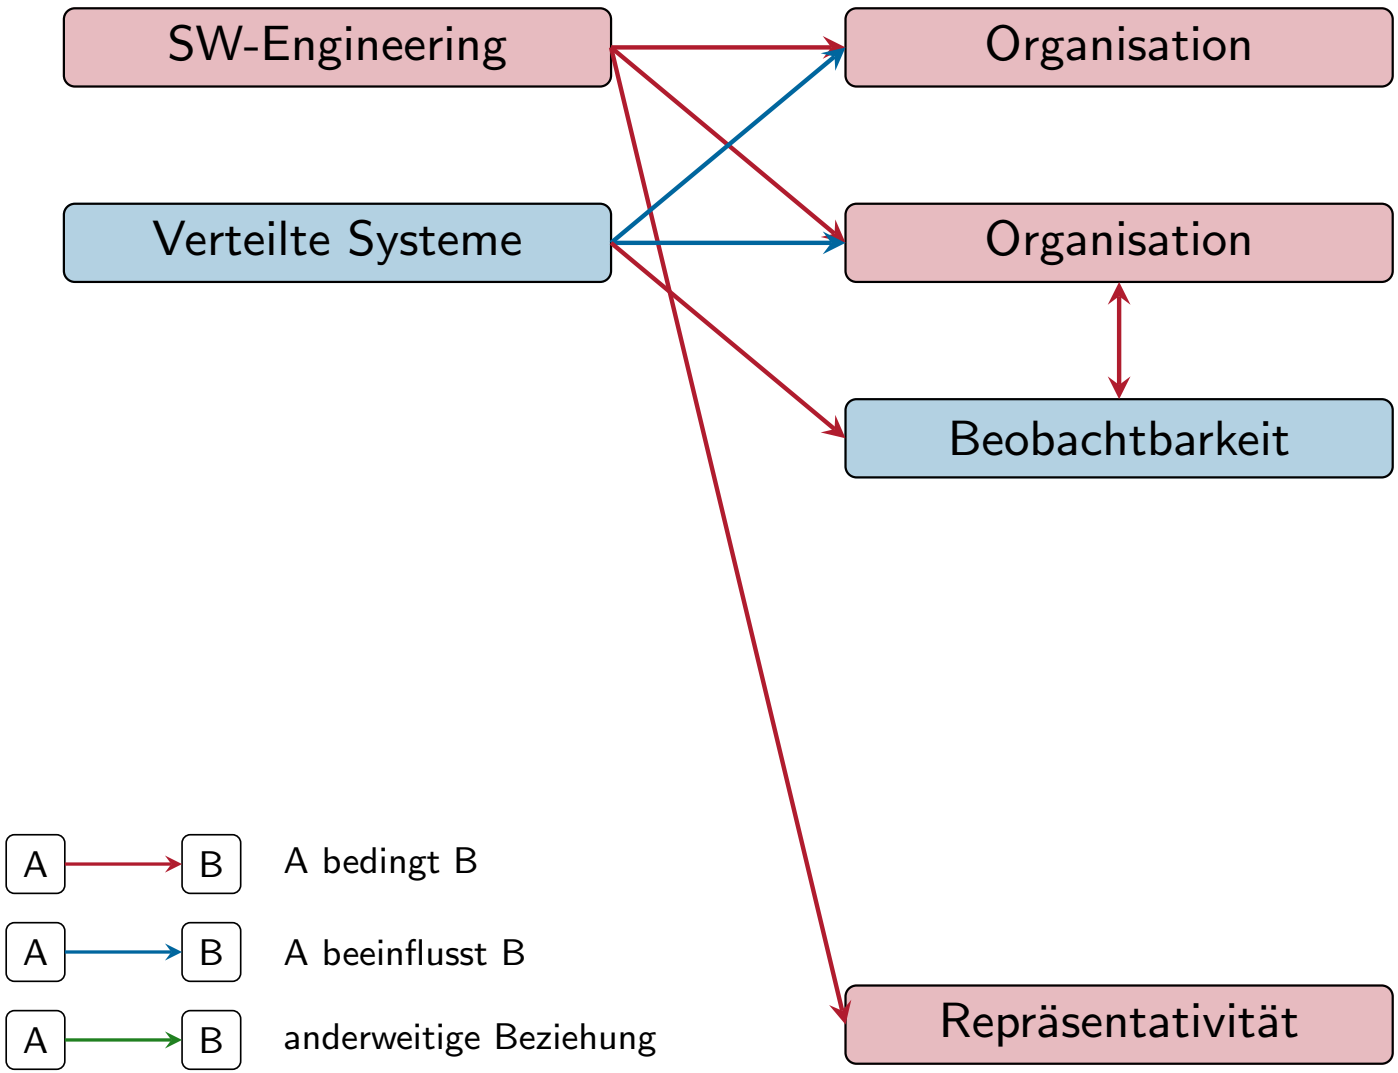

Problemfeld: Fokus „Echtzeitsysteme“

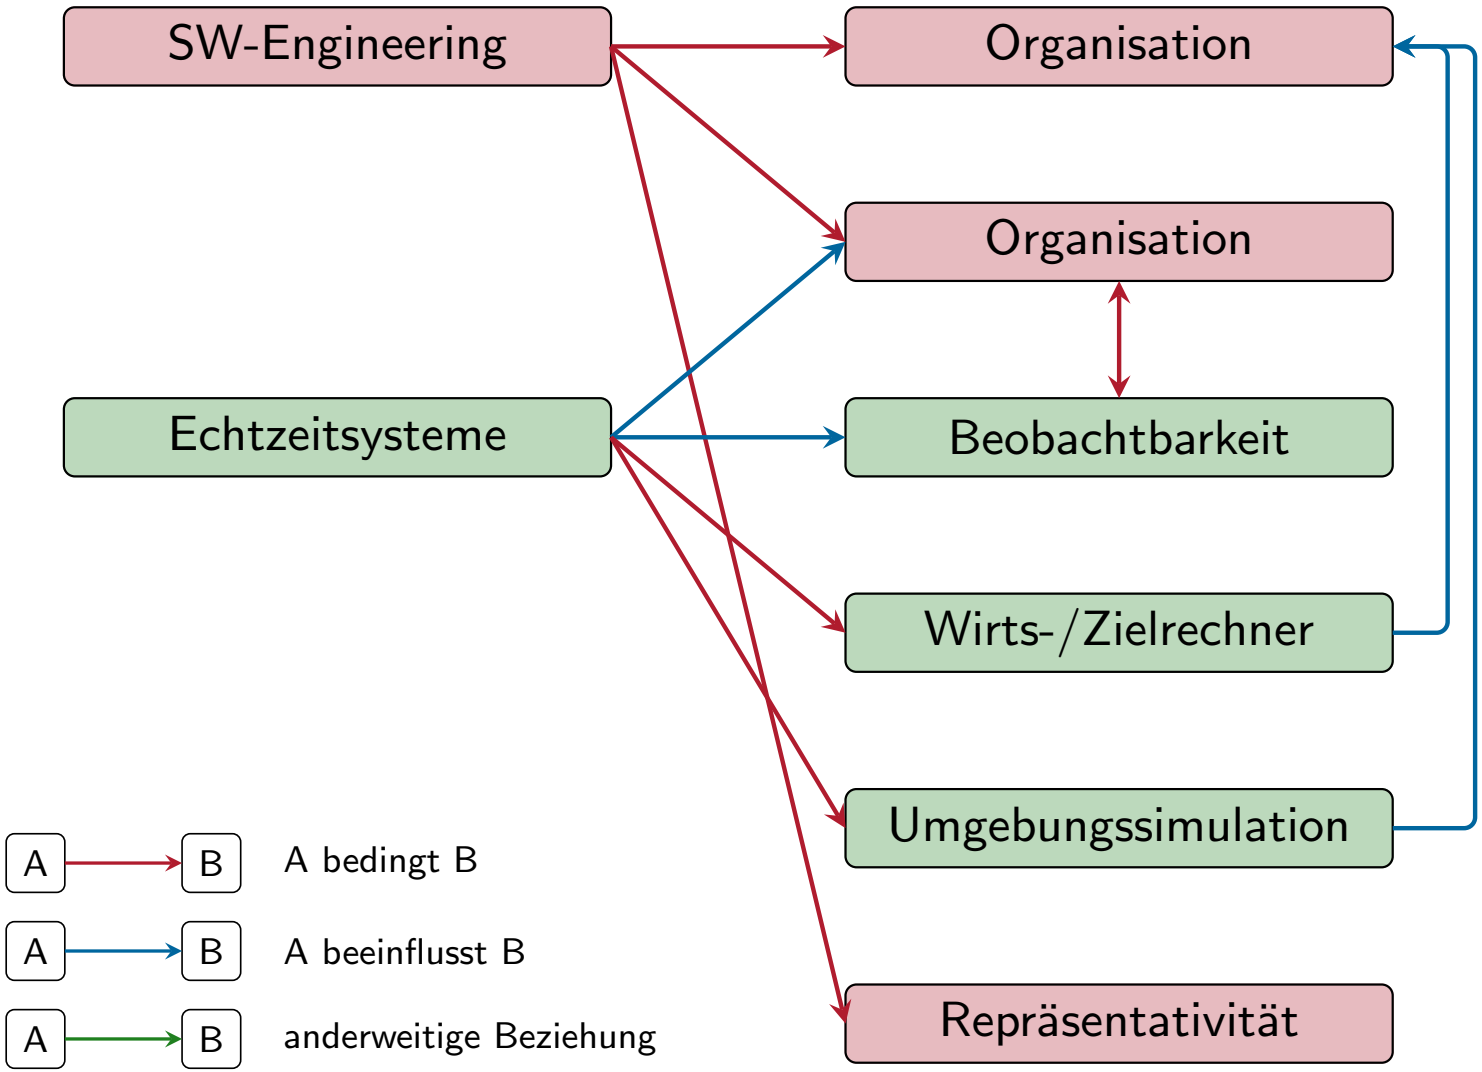

Beobachtbarkeit

Erfassen des relevanten Verhaltens des Systems und der Umwelt

- Was kann man beobachten?
  - Ausgaben bzw. Ergebnisse
  - Zwischenzustände und -ergebnisse
    - erfordern u.U. zusätzliche Ausgaben ($\leadsto$ aufwändig, häufiges Übersetzen)
    - Inspektion des Speichers mit einem Debugger
- Problem: Ausgaben beeinflussen das Systemverhalten
  - Ausgaben verzögern Prozesse, Nachrichten, ... $\leadsto$ Time-Out
- Problem: Debuggen Unmöglichkeit globaler Haltepunkte
  - perfekt synchronisierte Uhren existieren nicht

  $\leadsto$ Wie soll man Prozesse gleichzeitig anhalten?
- bekanntes Phänomen: **Probe Effect**

  $\leadsto$ „Vorführeffekt“ – sobald man hinsieht, ist der Fehler verschwunden

  $\leadsto$ muss vermieden oder kompensiert werden

„Probe Effect“: Verschärfung durch verteilte EZS

- Aspekt verteilte Systeme
  - „Probe Effect“ durch gleichzeitige Prozesse
    - Systemzustand verteilt sich auf mehrere, gleichzeitig ablaufende Prozesse
    - durch Beeinflussung einzelner Prozesse verändert sich der globale Zustand

    ⇝ andere Prozesse enteilen dem beeinflussten Prozess

    ⇝ ein Fehler lässt sich evtl. nicht reproduzieren

- Aspekt Echtzeitsysteme
  - „Probe Effect“ durch Zeitstempel
    - neben dem Datum ist häufig ein Zeitstempel notwendig
    - das Erstellen des Zeitstempels selbst benötigt Zeit (Auslesen eine Uhr, . . .)
    - die zu protokollierende Datenmenge wächst ebenfalls an
  - „Probe Effect“ durch Kopplung an die physikalische Zeit
    - das kontrollierte Objekt enteilt dem beeinflussten Prozess

    ⇝ auch einzelne Prozesse sind anfällig

„Probe Effect“: Lösungsmöglichkeiten

Ignoranz

- der „Probe Effect“ wird schon nicht auftreten

Minimierung

- hinreichend effiziente Datenaufzeichnung
- Kompensation der aufgezeichneten Daten
  - verhindert nicht die Verfälschung des globalen Zustands

Vermeidung

- Datenaufzeichnung existiert auch im Produktivsystem
- Einsatz dedizierter Hardware für die Datenaufzeichnung
- Einflussnahme wird hinter einer logischen Uhr verborgen
  - zeitliche Schwankungen sind nicht relevant

  $\rightsquigarrow$ solange sich eine gewisse Reihenfolge nicht ändert

Reproduzierbarkeit

Für die Fehlersuche muss man das Fehlverhalten nachstellen können!

- wichtige Testvariante: Regressionstests (engl. *regression testing*)
  - Wurde der Fehler auch wirklich korrigiert?
  - Hat die Korrektur neue Defekte verursacht?
- Voraussetzung für Regressionstests $\rightsquigarrow$ Reproduzierbarkeit
  - andernfalls ist keine Aussage zur Behebung des Fehler möglich
  - dasselbe Symptom könnte durch verschiedene Ursachen hervorgerufen werden
- Voraussetzung für die Reproduzierbarkeit ist:
  - Beobachtbarkeit und die
  - Kontrollierbarkeit des Systems
    - Wie sonst soll man das Fehlverhalten nachstellen?

Reproduzierbarkeit $\leftrightarrow$ Beobachtbarkeit

Fehlverhalten zu reproduzieren erfordert mehr Wissen, als es zu erkennen.

- nicht-deterministische Operationen
  - Abhängigkeiten z. B. vom Netzwerkverkehr
  - Zufallszahlen
- ungenügendes Vorabwissen
  - Fadensynchronisation
  - asynchrone Programmunterbrechungen
  - Zeitbasis der untersuchten Systeme

☞ dies sind relevante Ereignisse
  - sie beeinflussen den Programmablauf
  - hängen von der Anwendung ab

$\rightsquigarrow$ Identifikation und Beobachtung erforderlich

Kontrollierbarkeit

- Abspielen relevanter Ereignisse
  - Beibehaltung der ursprünglichen Reihenfolge
  - zeitlich akkurat
  - umfasst alle relevanten Ereignisse
    - asynchrone Programmunterbrechungen
    - interne Entscheidungen des Betriebssystems $\leadsto$ Einplanung, Synchronisation
- Simulierte Zeit statt realer, physikalischer Zeitbasis
  - Entkopplung von der Geschwindigkeit der realen Welt

  $\leadsto$ ansonsten könnte die Fehlersuche sehr, sehr lange dauern ...
- Ansätze zur Kontrollierbarkeit
  - sprachbasierte Ansätze
    - statische Quelltextanalyse
    - Quelltexttransformation
  - implementierungsbasierte Ansätze
    - Record & Replay

Statische Quelltextanalyse

- Identifizierung möglicher Ausführungsszenarien
  - Berücksichtigung von Kommunikation, Synchronisation, Einplanung, ...
- Ausführungsszenarien werden erzwungen

  ⇝ Random Scheduler
  - gleichzeitige Prozesse $\mapsto$ sequentielles Programm
  - teste Sequentialisierungen statt der gleichzeitigen Prozesse
- Vorgehen ist mit grob-granularem Model Checking vergleichbar

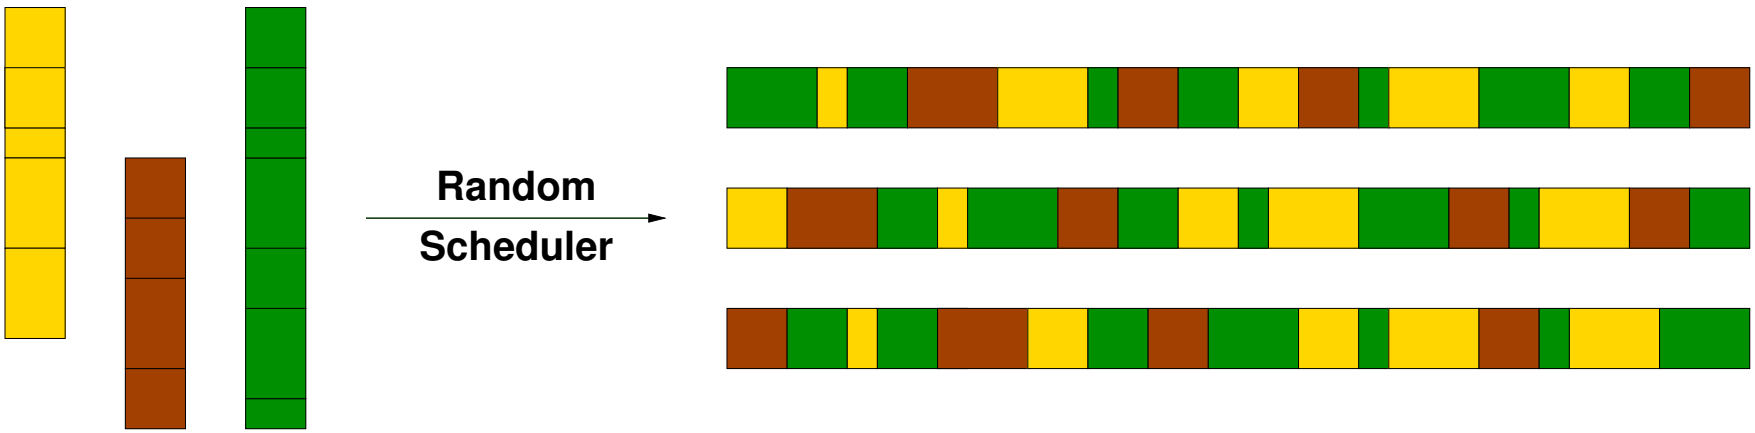

Record & Replay

- Monitoring zur Laufzeit
  - Aufzeichnung aller relevanten Ereignisse

  ⇝ event histories bzw. event traces

☞ dieser Mitschnitt wird später erneut abgespielt

- Vorteil: Lösungen für verteilte Echtzeitsysteme existieren
  - vermeiden „Probe Effect“
  - decken eine Vielzahl verschiedener Ereignisse ab
    - Systemaufrufe, Kontextwechsel, asynchrone Unterbrechungen, ...
    - Synchronisation, Zugriffe auf gemeinsame Variablen, ...
- Nachteil: enorm hoher Aufwand
  - häufig ist Spezialhardware erforderlich
  - es fallen große Datenmengen an
    - Aufzeichnung erfolgt i. d. R. auf Maschinencodeebene, Eingaben, ...
  - es können nur beobachtete Szenarien wiederholt werden
    - Änderungen am System machen existierende Mitschnitte u. U. wertlos
  - Wiederholung & Mitschnitt müssen auf demselben System stattfinden

Gliederung

Zusammenfassung

Testen ist **die** Verifikationstechnik in der Praxis!

- Modul-, Integrations-, System- und Abnahmetest
- ☞ kann die Absenz von Defekten aber nie garantieren

Modultests sind i. d. R. Black-Box-Tests

- Black-Box- vs. White-Box-Tests
- McCabe's Cyclomatic Complexity $\rightsquigarrow$ Minimalzahl von Testfällen
- Kontrollflussorientierte Testüberdeckung
  - Anweisungs-, Zweig-, Pfad- und Bedinungsüberdeckung
  - Angaben zur Testüberdeckung sind immer relativ!

Systemtests für verteilte Echtzeitsysteme sind herausfordernd!

- Problemfeld: Testen verteilter Echtzeitsysteme
  - SW-Engineering, verteilte Systeme, Echtzeitsysteme
  - Probe-Effect, Beobachtbarkeit, Kontrollierbarkeit, Reproduzierbarkeit

Literaturverzeichnis

[1] Laplante, P. A.:
Real-Time Systems Design and Analysys.
third.
John Wiley & Sons, Inc., 2004. –
ISBN 0–471–22855–9

[2] OSEK/VDX Group:
Operating System Specification 2.2.3 / OSEK/VDX Group.
2005. –
Forschungsbericht. –
http://portal.osek-vdx.org/files/pdf/specs/os223.pdf, visited 2011-08-17

[3] Schütz, W. :
Fundamental issues in testing distributed real-time systems.
In: *Real-Time Systems Journal* 7 (1994), Nr. 2, S. 129–157.
http://dx.doi.org/10.1007/BF01088802. –
DOI 10.1007/BF01088802. –
ISSN 0922–6443