Verlässliche Echtzeitsysteme

Dynamisches Testen

Peter Ulbrich

Lehrstuhl für Verteilte Systeme und Betriebssysteme

Friedrich-Alexander-Universität Erlangen-Nürnberg

`https://www4.cs.fau.de`

02. Juni 2016

Funktionale und nicht-funktionale Eigenschaften

Welche Aspekte spielen bei der zuverlässigen Entwicklung eine Rolle?

☞ Korrektheit der Software hat viele Gesichter
- Wurde das 1) richtige 2) korrekt implementiert?

→ Alle relevanten Eigenschaften sind zu überprüfen!

1 Funktionale Eigenschaften (hier: Übereinstimmung mit der Spezifikation)
- Müssen explizit implementiert werden ↦ `int regelschritt(int sensorwert)`
- Eine fehlerhafte Funktion kann nicht-funktional korrekt sein

2 Nicht-funktionale Eigenschaften (z.B. Laufzeitverhalten)
- Können nur implizit implementiert werden
- Sind querschneidend ⇝ erst im konkreten Kontext bestimmt
- Eine korrekte Funktion kann nicht-funktional fehlerhaft sein

⚠ Robustheit (Kapitel 3-6) ist eine nicht-funktionale Eigenschaft

⚠ Es kommt auf die Betrachtungsebene an!
- Laufzeitfehler (engl. *bugs*) stellen eine nicht-funktionale Eigenschaft dar
- Aus Sicht des Übersetzers (engl. *compilers*) sind dies jedoch funktionale Fehler

Zuverlässig Software entwickeln?

☞ Ziel: Aussagen zur Korrektheit von funktionalen und nicht-funktionalen Eigenschaften von Software treffen
- Fokus der Vorlesung: Korrektheit oder zumindest Absenz von Defekten
- Schrittweise Annäherung über Qualität und Verhalten

Hierfür existieren unterschiedliche Ansätze:
- Informelle Methoden
  - Inspection, Review, Walkthrough, ...
- Analytische Methoden
  - Metriken, Kodierrichtlinien, ...

} Aussagen über die Qualität

- Synamisches Testen
  - Black-Box, White-Box, Regression, Unit, ...
- Formale Methoden
  - Statische Code-Analyse, Model Checking, ...

} Aussagen über das Verhalten

☞ In dieser Vorlesung steht das Testen des Verhaltens im Vordergrund

Gliederung

Einordnung in den Entwicklungsprozess

Softwareentwicklung nach dem V-Modell wird zugrunde gelegt

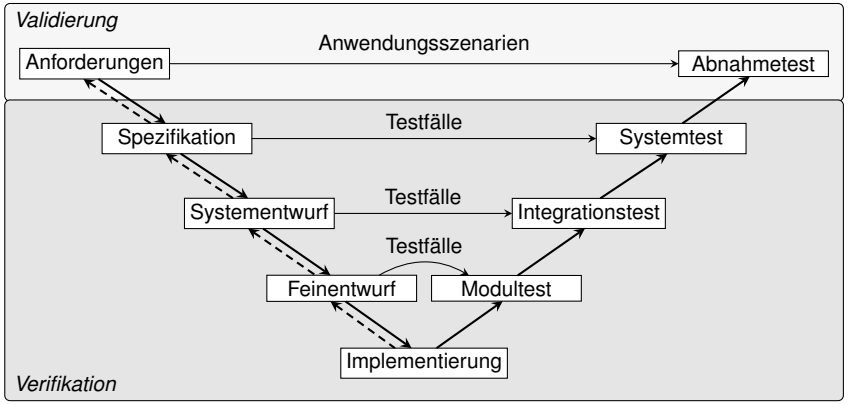

- Weit verbreitetes Vorgehensmodell in der Softwareentwicklung
  - Absteigender Ast ⇝ Spezifikation, Entwurf, Implementierung
  - Aufsteigender Ast ⇝ Verifikation & Validierung
  - Querbeziehungen ⇝ Testfallableitung

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 ⟷ 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

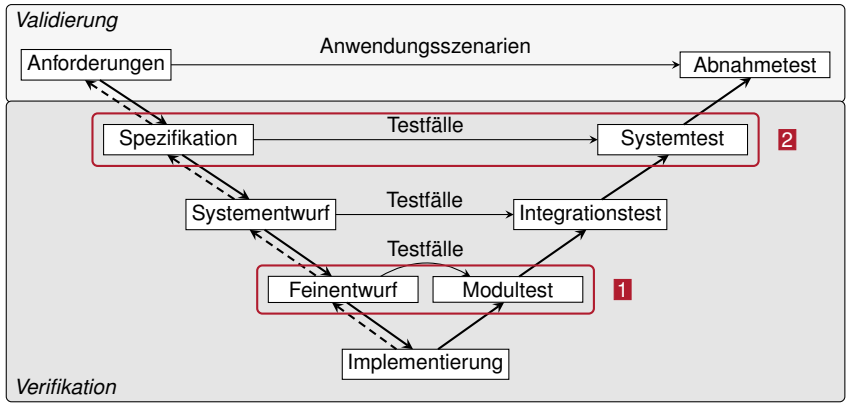

1 Modultests ⇝ Grundbegriffe und Problemstellung
→ Black- vs. White-Box, Testüberdeckung

2 Systemtest ⇝ Testen verteilter Echtzeitsysteme
→ Problemstellung und Herausforderungen

Eigenschaften von Modultests

- Modultests beziehen sich auf kleine Softwareeinheiten
  - Meist auf Ebene einzelner Funktionen
    - Die Testbarkeit ist zu gewährleisten ⇝ 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

  → Regressionstests (engl. *regression testing*) ⇝ Automatisierung notwendig
- Modultests sollten auch den Fehlerfall prüfen
  - Es genügt nicht, zu prüfen, dass ein korrektes Ergebnis berechnet wurde

  → Der Fehlerfall (Eingaben, Zustand, ...) soll einbezogen werden
- Modultest betrachten die Schnittstelle
  - Anwendung des Design-By-Contract-Prinzips ⇝ Black-Box-Tests
  - Interne Details (⇝ 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 (fehlerfrei) 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 (fehlerfrei) implementiert?

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

Problem: Kombinatorische Explosion

Ohne Einsicht in die Programmstruktur ist Testen sehr mühsam!

- Beispiel: Modultests für OSEK OS [3]
  - 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)
    - → **24** Varianten für jeden Testfall
- Black-Box ⇝ kein Wissen über die interne Struktur nutzbar
  - konservative Annahme: Parameter beeinflussen sich gegenseitig
  - → Alle Kombinationen sind relevant: **Kombinatorische Explosion!**
- Kombination aus Black- und White-Box-Tests
  - → Unabhängigkeit der Parameter kann evtl. sichergestellt werden
  - → Reduktion der Testfälle bzw. deren Varianten

Gliederung

Hat man genug getestet?

Wie viele Testfälle sind genug Testfälle?

- Kriterium: Anzahl der Testfälle
  - Basierend auf Metriken
    - McCabe's Cyclomatic Complexity (MCC), Function/Feature Points, ...
  - Mithilfe von Statistiken aus früheren Projekten
    - Kennzahlen früherer Projekte ⇝ Anzahl zu erwartender Defekte
    - Wie viele Defekte hat man bereits gefunden, wie viele sind noch im Produkt?
    - Wie viele Defekte will/kann man ausliefern?
    - → Übertragbarkeit?
- 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 [2, 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	Verzweigung	Do-While	Fallunterscheidung
C = 1	C = 2	C = 2	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?

$C_0 = s/S$ Anweisungsüberdeckung (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

→ Zweigüberdeckung und dafür benötigte Testfälle sind nicht proportional

→ Primitive Zweige sind unabhängig von anderen Zweigen

- Findet nicht erreichbare Zweige, Defekterkennungsrate ca. 33%
- Nachteile: unzureichende Behandlung von
  - Abhängigen Verzweigungen
  - Schleifen $\rightsquigarrow$ Pfadüberdeckung
  - Komplexe 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;
}
```

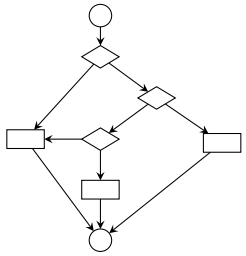

- Anweisungsüberdeckung
  - Test 1: `foo(0,0,0)`
  - Test 2: `foo(0,1,-1)`
  - Test 3: `foo(2,0,1)`
- Zweigüberdeckung
  - Test 1: `foo(0,0,0)`
  - Test 2: `foo(0,1,-1)`
  - Test 3: `foo(2,0,1)`
  - Test 4: `foo(2,1,1)`
- 100% Zweigüberdeckung ↦ 100% Anweisungsüberdeckung
- Zweigüberdeckung: Weite industrielle 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 1-mal betreten, alle Pfade im Rumpf abgearbeitet
interior	Beschränkung: mit 2 bzw. 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
  - Ihre 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`

- Einfachbedingungsüberdeckung

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)

Testen hat seine Grenzen!

☞ Testen ist im Allgemeinen sehr aufwändig!
- Ziel müssen möglichst vollständige Tests sein!
- Aber woher weiß man, dass man genügend getestet hat?

⚠ Vollständige Tests sind in der Praxis unrealistisch
- „... wir haben schon lange keinen Fehler mehr gefunden ...“
  - Eine Auffassung, der man oft begegnet
  - → Der entscheidende Fehler kann sich immer noch versteckt halten
- Therac 25 (s. Folie II/3 ff.) wurde > 2700 Stunden betrieben

Fehlerfreie Software durch Testen?
- Praktisch sind Tests für einen Korrektheitsnachweis ungeeignet!
- Testen kann nur das Vertrauen in Software erhöhen!

- Formale Methoden gehen einen anderen Weg
  - Weisen Übereinstimmung anstatt Abweichung nach
  - Gegenstand kommender Vorlesungen

Gliederung

Testen: Ein Problem des „SW-Engineering“

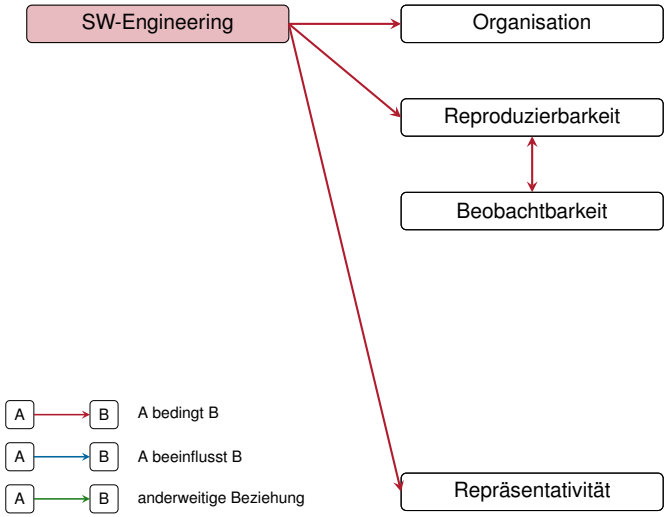

Problemfeld: Reproduzierbarkeit

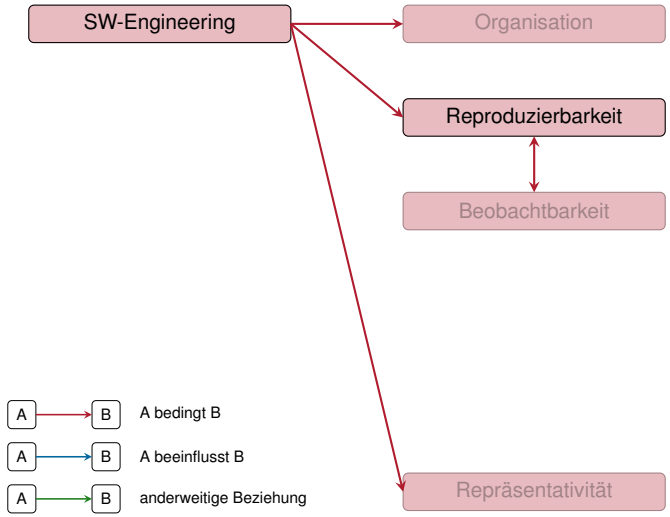

Reproduzierbarkeit

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 ⇝ Reproduzierbarkeit
- Andernfalls ist keine Aussage zur Behebung des Fehler möglich
- Verschiedene Ursachen können dasselbe Symptom hervorrufen

⚠ Voraussetzung für die Reproduzierbarkeit ist:
- Beobachtbarkeit und die
- Kontrollierbarkeit des Systems

→ Testfälle müssen sich deterministisch verhalten
(vgl. Replikdeterminismus IV/15 ff)

Reproduzierbarkeit ⟷ Beobachtbarkeit

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

⚠ Nicht-deterministische Operationen
- Abhängigkeiten z. B. vom Netzwerkverkehr
- Zufallszahlen, interne Systemzustände (`syscall()`), ...

⚠ Ungenügendes Vorabwissen
- Fadensynchronisation
- Asynchrone Programmunterbrechungen (engl. *interrupts*)
- Zeitbasis der untersuchten Systeme

☞ Dies sind relevante Ereignisse
- Sie beeinflussen den Programmablauf
- Hängen von der Anwendung ab

→ Identifikation und Beobachtung erforderlich

Problemfeld: Fokus „Verteilte Systeme“

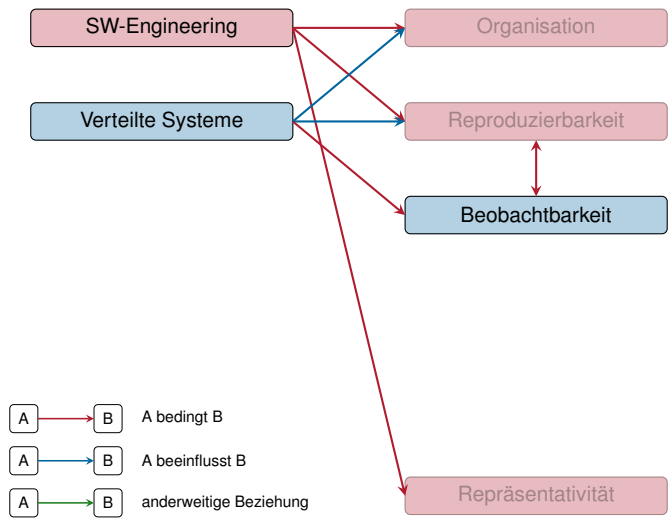

Beobachtbarkeit verteilter EZS

Erfassen des relevanten Verhaltens des Systems und der Umwelt

☞ Beobachtung aller relevanten Zustände des Systems
- Ausgaben bzw. Ergebnisse
- Zwischenzustände und -ergebnisse

■ Problem: Ausgaben beeinflussen das Systemverhalten
- Ausgaben verzögern Prozesse, Nachrichten, . . . ⇝ Termin

■ Problem: Debuggen ↦ Unmöglichkeit globaler Haltepunkte
- Perfekt synchronisierte Uhren existieren nicht

→ Wie soll man Prozesse gleichzeitig anhalten?

⚠ Bekanntes Phänomen: Untersuchungseffekt (engl. *probe effect*)[1]
- Vergleiche Heisenbugs auf Folie III/26

→ „Vorführeffekt“ – sobald man hinsieht, ist der Fehler verschwunden

→ Muss vermieden oder kompensiert werden

[1] Der Effekt/der Einflussnahme auf eine Komponente oder ein System durch die Messung. [1]

Problemfeld: Fokus „Echtzeitsysteme“

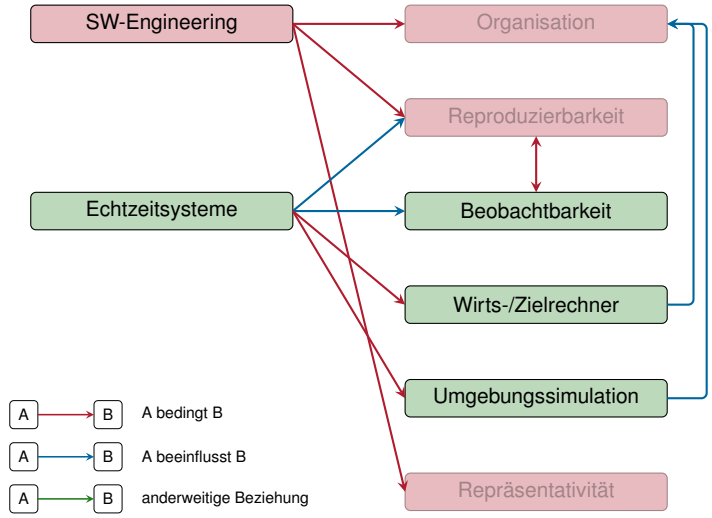

Untersuchungseffekt: Verschärfung durch zeitlichen Aspekt

■ Untersuchungseffekt auf 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

■ Untersuchungseffekt auf 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

■ Untersuchungseffekt bei Kopplung an die physikalische Zeit
- Das kontrollierte Objekt enteilt dem beeinflussten Prozess

→ Auch einzelne Prozesse sind anfällig

Untersuchungseffekt: Lösungsmöglichkeiten

Ignoranz

- Der Untersuchungseffekt 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
  - → Solange sich eine gewisse Reihenfolge nicht ändert

Kontrollierbarkeit: Ein umfassendes Problem

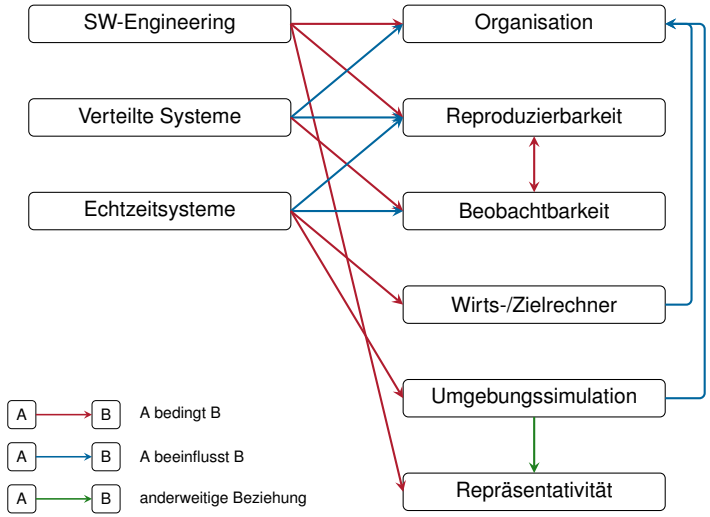

Kontrollierbarkeit

☞ Deterministische Ausführung relevanter Ereignisse

- Beibehaltung der ursprünglichen Reihenfolge
- Zeitlich akkurat
- Umfasst alle relevanten Ereignisse
  - Asynchrone Programmunterbrechungen
  - Interne Entscheidungen des Betriebssystems ⇝ Einplanung, Synchronisation

- Simulierte Zeit statt realer, physikalischer Zeitbasis
  - Entkopplung von der Geschwindigkeit der realen Welt
  - → Ansonsten könnte die Fehlersuche sehr, sehr lange dauern . . .

- Ansätze zur Kontrollierbarkeit
  - Analytische Ansätze
    - Record & Replay
  - Konstruktive Ansätze
    - Statische Quelltextanalyse
    - Quelltexttransformation

Record & Replay

☞ Vermessung (engl. *monitoring*) zur Laufzeit

- Aufzeichnung aller relevanten Ereignisse
- Dieser Mitschnitt wird später erneut abgespielt
- → Event histories bzw. event traces

- Vorteil: Lösungen für verteilte Echtzeitsysteme existieren
  - Vermeiden Untersuchungseffekt
  - 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

Konstruktion von Ausführungsszenarien

- Identifizierung möglicher Ausführungsszenarien
  - Berücksichtigung von Kommunikation, Synchronisation, Einplanung, ...
- Ausführungsszenarien werden erzwungen
  - → Random Scheduler
    - Gleichzeitige Prozesse ↦ sequentielles Programm
  - Teste Sequentialisierungen statt der gleichzeitigen Prozesse
- Vorgehen ist mit grob-granularem Model Checking vergleichbar

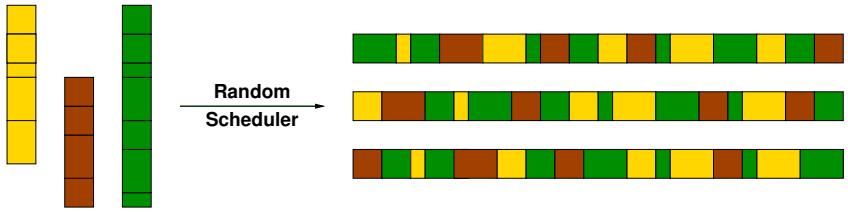

Herausforderungen beim Testen verteilter EZS [4]

Ergeben sich vor allem aus der 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 ⇝ Allokation, Kommunikation, ...
  - Beobachtung und Reproduzierbarkeit des Systemverhaltens
  - Fehlende globale Zeit ⇝ kein eindeutiger globaler Zustand
    - Globale, konsistente Abbilder sind ein großes Problem

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 ⇝ Minimalzahl von Testfällen
  - Kontrollflussorientierte Testüberdeckung
    - Anweisungs-, Zweig-, Pfad- und Bedinungsüberdeckung
    - Angaben zur Testüberdeckung sind immer relativ!
- Testdurchführung in (verteilten) Echtzeitsystemen sind herausfordernd!
  - Problemfeld: Testen verteilter Echtzeitsysteme
    - SW-Engineering, verteilte Systeme, Echtzeitsysteme
    - Untersuchungseffekt, Beobachtbarkeit, Kontrollierbarkeit, Reproduzierbarkeit

Literaturverzeichnis

[1] Hamburg, M. ; Hehn, U. :
ISTQB®/GTB Standardglossar der Testbegriffe.
(2010)

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

[3] 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 2014-09-29

[4] 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