Vorlesung "Softwaretechnik"
Buchkapitel 11
Analytische Qualitätssicherung 1

Lutz Prechelt

Freie Universität Berlin, Institut für Informatik

- QS: Was, wann, warum?
- Analytische Qualitätssicherung
  - statisch, dynamisch
- Testen
  - Ziele
- Testfallauswahl
  - Funktionstest (black box)
  - Strukturtest (white box)
- Testgegenstandsauswahl
- Ermitteln des erwarteten Verhaltens
- Wiederholung von Tests
  - insbes. Testautomatisierung

Wo sind wir?: Taxonomie "Die Welt der Softwaretechnik"

Freie Universität Berlin

Welt der Problemstellungen:

- Produkt (Komplexitätsprob.)
  - Anforderungen (Problemraum)
  - **Entwurf (Lösungsraum)**
- Prozess (psycho-soziale P.)
  - Kognitive Beschränkungen
  - Mängel der Urteilskraft
  - Kommunikation, Koordination
  - Gruppendynamik
  - Verborgene Ziele
  - **Fehler**

Welt der Lösungsansätze:

- Technische Ansätze ("hart")
  - Abstraktion
  - Wiederverwendung
  - Automatisierung
- Methodische Ansätze ("weich")
  - Anforderungsermittlung
  - Entwurf
  - **Qualitätssicherung**
  - Projektmanagement

Wo sind wir?: Qualitätssicherung

- Einsicht: Man macht beim Bau von SW zahlreiche Fehler
  - die häufig zu schwerwiegenden Mängeln führen

- Prinzipien:
  - **Konstruktive Qualitätssicherung**: Ergreife vorbeugende Maßnahmen, um zu *vermeiden*, dass etwas falsch gemacht wird (Qualitätsmanagement, Prozessmanagement)
  - ***Analytische Qualitätssicherung***: Verwende prüfende Maßnahmen, die entstandene Mängel aufdecken
  - ***Softwaretest***: dynamische Prüfung
  - **Durchsichten**: manuelle statische Prüfung

Qualitätssicherung (QS): Was ist das?

Freie Universität Berlin

- Qualitätssicherung (QS, engl. quality assurance, QA)
  - Gesamtheit aller Maßnahmen, die nicht darauf zielen, ein Produkt *überhaupt* fertig zu stellen, sondern darauf, es *in guter Qualität* fertig zu stellen

2 grundlegende Herangehensweisen:

- **Analytische QS**: Prüfend
  - Untersuche (Teil)Produkte nach ihrer Fertigstellung auf Qualität
  - Bessere nach, wo Mängel auftreten
- **Konstruktive QS**: Vorbeugend
  - Gestalte den Konstruktionsprozess und sein Umfeld so, dass Qualitätsmängel seltener werden
  - Beseitige bei entdeckten Mängeln nicht nur den Mangel selbst, sondern auch seine Ursache(n) und ggf. deren Ursache(n)

Qualitätsmerkmale von Software (ganz grob)

Freie Universität Berlin

Externe Qualitätseigenschaften (aus Benutzersicht)

- Benutzbarkeit
  - Bedienbarkeit, Erlernbarkeit, Robustheit, …
- Verlässlichkeit
  - Zuverlässigkeit, Verfügbarkeit, Sicherheit, Schutz
- Brauchbarkeit
  - Angemessenheit, Geschwindigkeit, Skalierbarkeit, Pflege, …
- …

(Man kann diese Listen auch deutlich anders machen, siehe z.B. ISO 9126)

Interne Qualitätseigenschaften (aus Entwicklersicht)

- Zuverlässigkeit
  - Korrektheit, Robustheit, Verfügbarkeit, …
- Wartbarkeit
  - Verstehbarkeit, Änderbarkeit, Testbarkeit, Korrektheit, Robustheit
    - Dafür nötig sind z.B. Strukturiertheit, Dokumentiertheit, Flexibilität, etc.
- Effizienz
  - Speichereffizienz, Laufzeiteff., Skalierbarkeit, …
- …

Interne Q. sind Mittel zum Zweck!

QS: Wann macht man das? Wer ist zuständig?

Freie Universität Berlin

- Faustregel: Dauernd und Jede/r (Grundprinzip von TQM)
- Analytische QS:
  - Untersuche jedes Teilprodukt so früh wie möglich
  - Je früher ein Mangel entdeckt wird, desto weniger Schaden richtet er an [Zugleich Antwort auf die Frage "Warum QS?"]
    - z.B. Anforderungsmängel erst nach Auslieferung zu beseitigen kostet evtl. über tausendmal mehr als bei der Anforderungsbestimmung
  - Analytische QS ist in der SWT Bestandteil aller Aktivitäten
- Konstruktive QS:
  - Beginne damit vor der eigentlichen Entwicklungsarbeit
    - Gestaltung von Organisation und Arbeitsumfeld
    - Auswahl von Prozessen, Technologie, Strategie
  - Lerne aus Projekterfahrungen
    - Post-mortem: Zusammentragen von Erfahrungen nach Projektende und Umsetzen in Prozessverbesserungen
  - Korrigiere den Prozess ggf. auch unterwegs

Übersicht

Analytische QS:

- **Dynamische Verfahren (Test)**
  - **Defekttest**
  - Benutzbarkeitstest
  - Lasttest
  - Akzeptanztest
- Statische Verfahren
  - Manuelle Verfahren
    - Durchsichten, Inspektionen
  - Automatische Verfahren
    - Modellprüfung
    - Quelltextanalyse

Konstruktive QS:

- Test- und Durchsichtsmgmt.
- Prozessmanagement
- Projektmanagement, Risikomanagement

Qualitätsmerkmale von Software (ganz grob)

Freie Universität Berlin

Externe Qualitätseigenschaften (aus Benutzersicht)

- Benutzbarkeit
  - Bedienbarkeit, Erlernbarkeit, Robustheit, ...
- Verlässlichkeit
  - Zuverlässigkeit, Verfügbarkeit, Sicherheit, Schutz
- Brauchbarkeit
  - Angemessenheit, Geschwindigkeit, Skalierbarkeit, Pflege, ...
- ...

(Man kann diese Listen auch ganz anders machen)

Ziel von Defekttests

Interne Qualitätseigenschaften (aus Entwicklersicht)

- Zuverlässigkeit
  - Korrektheit, Robustheit, Verfügbarkeit, ...
- Wartbarkeit
  - Verstehbarkeit, Änderbarkeit, Testbarkeit, Korrektheit, Robustheit
    - Dafür nötig sind z.B. Strukturiertheit, Dokumentiertheit, Flexibilität, etc.
- zienz
  - Speichereffizienz, Laufzeiteffizienz, Skalierbarkeit
- ...

Interne Q. sind Mittel zum Zweck!

Defekttest: Terminologie

- **Testen**: Anwenden eines *Testfalls* auf einen *Testgegenstand*
- **Testfall**: ein Tupel, das erwartetes Verhalten beschreibt
  - (Systemzustand, Eingaben, Systemverhalten)
    - Zustand+Eingaben heißen auch **Testeingabe**
    - Verhalten heißt auch **Testausgabe**
- **Testgegenstand (Komponente)**: System oder Teil davon, das/der getestet werden soll
  - z.B. ein Modul, mehrere Module,
    ein Subsystem, mehrere Subsysteme
- **Testdurchführung** (Testausführung):
  - Herstellen des Zustands,
  - Aufruf des Testgegenstands,
  - Übermitteln der Eingaben,
  - Vergleich des Verhaltens mit dem erwarteten
    - **Testergebnis**: Übereinstimmung (keine Erkenntnis) oder Abweichung (Defekt erkannt: Erfolg!)

Defekttest: Terminologie (2)

- Ziel des Defekttests ist Herbeiführen von **Versagen (*failure*)**
  - Also einem falschen Verhalten des Programms
    - Falsch im Sinne der Spezifikation (soweit vorhanden), der Anforderungen (wenn klar) oder der Erwartungen (andernfalls)
- Versagen entsteht aufgrund eines **Defekts (*defect, fault*)** im Programm
  - Eventuell führen erst mehrere Defekte gemeinsam dazu
  - Aber nicht jeder Defekt führt zu einem Versagen
- Ein Defekt entsteht aufgrund eines **Fehlers (*error*)** der Softwareentwickler
  - Ein Fehler ist entweder ein **Falschtun (*commission*)** oder ein **Versäumnis (*omission*)**
  - Nicht unbedingt beim Kodieren, vielleicht auch bei Anforderungen oder Entwurf
- Fehlern liegt entweder ein **Irrtum (*misconception*)** oder ein **Versehen (*blunder*)** zu Grunde

Defekttest: Teilprobleme

- **Wie wählt man Zustände und Eingaben aus?**
- Wer wählt Zustände und Eingaben aus?
- Wie wählt man Testgegenstände aus?
- Wie ermittelt man das erwartete Verhalten?
- Wann wiederholt man Tests?
- Wann/wie kann und sollte man Tests automatisieren?
- Wann kann/sollte man mit dem Testen aufhören?

Wie wählt man Zustände und Eingaben aus?

Freie Universität Berlin

Vorgehensweisen:

- **Funktionstest (*functional test, black box test*)**
  - Äquivalenzklassen
  - Fehlerfälle
  - Extremfälle
- Strukturtest (*structural test, white box test, glass box test*)
- Bekannte Versagensfälle
- Allgemeine Erfahrung, Intuition

Funktionstest (functional test, black box test)

Freie Universität Berlin

Wählt Testfälle durch Betrachtung der Spezifikation (Schnittstelle) der Komponente:

- Für jeden Fall mit andersartigem Verhalten wähle mindestens einen Testfall

- Gruppen solcher Fälle:
  - Äquivalenzklassen gleichwertiger Eingaben
  - Fehlerfälle
  - Heuristik: Randfälle

Funktionstest Beispiel 1: sqrt()

- Spezifikation (java.lang.Math):
  "**`public static double sqrt(double a)`**
  - Returns the correctly rounded positive square root of a double value"

- Testeingaben?
  - 0 1 Fixpunkte
  - -0,164 Fehlerfall
  - 0,5 (wird größer)
  - 1,5 (wird kleiner)
  - Randfälle:
    - Double.NaN
    - Double.POSITIVE_INFINITY

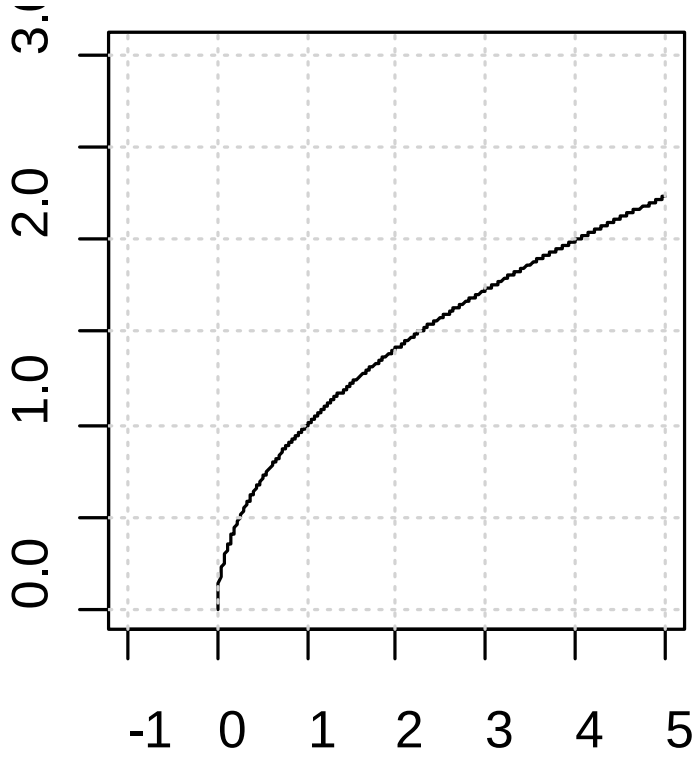

- Beachte: Kein Zustand relevant, sehr klare Semantik
  - So simpel ist es in der Praxis nur ganz selten

Funktionstest
Beispiel 2: addKeyListener()

- Jede *Component* in einem Java Swing GUI (z.B. ein JButton) kann einen oder mehrere *KeyListener* haben
  - Ein *KeyListener* ist ein Objekt mit Methoden, die bei Tastendrücken aufgerufen werden:
    - *keyPressed(KeyEvent e)*:
      Invoked when a key has been pressed
    - *keyReleased(KeyEvent e)*, *keyTyped(KeyEvent e)* entsprechend

- Wir testen das Zufügen von *KeyListeners* zu *Components*
- Spezifikation (java.awt.Component)
  "**`public void addKeyListener(KeyListener l)`**
  - Adds the specified key listener to receive key events from this component."
- Testfälle: Ersten *KeyListener* zufügen, weiteren K. zufügen, gleichen K. nochmals zufügen, *null* zufügen
  - Zerlegung ist bei weitem nicht eindeutig

Funktionstest
Beispiel 2: addKeyListener()

Freie Universität Berlin

- Testfälle: Ersten *KeyListener* zufügen, weiteren K. zufügen, gleichen K. nochmals zufügen , *null* zufügen
  - Zerlegung ist bei weitem nicht eindeutig
- Aber was ist das "erwartete Verhalten"?
  - 1. Listener sind zugefügt laut getKeyListeners()? oder
  - 2. Listener werden aufgerufen, wenn ein Tastendruck passiert?
    - Ist die Reihenfolge relevant? Ist sie sichergestellt?
    - Was passiert, wenn ich den selben Listener zweimal zugefügt hatte?
    - Was passiert (soll passieren), wenn ein Listener eine Ausnahme wirft?
    - Ist *null* zufügen erlaubt? Was bedeutet es?

Moral von der Geschicht':

- Oft wird erst beim Testen die Spezifikation richtig geklärt!
  - Kein gutes Zeichen! Dokumentation nachbessern!
  - Moderner Ansatz oft: Die Tests stellen die Spezifikation dar
    - automatisierte Tests

Funktionstest
Beispiel 3: Audioplayer

- Spezifikation: ???
  - (nur ganz vage in Hilfe)
  - Fehlt in der Realität oft!
- Beschränkung auf wichtigste Funktionen:
  - Laufwerkstasten:

- Zustände erraten (wären eigentlich der Spez. zu entnehmen):
  - Stopp, Pause, Spielt 1. Titel, Spielt letzten T., Spielt mittleren T.
  - Zustandsmenge wäre größer, wenn wir auch Zufallsfunktion (shuffle) und Endlos (repeat) testen würden
  - Kluge Wahl der Zustandsmenge ist entscheidend für den Test!
- Testfälle:
  - Teste jede Taste in jedem Zustand: 5 x 5 = 25 Testfälle

Funktionstest: Quellen von Spezifikationen

Freie Universität Berlin

Wo sollte die Spezifikation stehen?

- API-Beschreibungen (ggf. ist das z.T. der Test selbst)
  - Für Klassen, Module, Komponenten
- Use Cases oder förmliche Spezifikation
  - Für interaktive Systemteile (evtl. auch für interne)
- Benutzerhandbücher
  - Für interaktive Systemteile, falls komplex
    - (Viele Handbücher sind in dieser Hinsicht jämmerlich)

- Diese Dokumente müssen stets aktuell gehalten werden
  - Sonst wird der Test entweder teilweise sinnlos oder unnötig aufwändig

Funktionstest: Zusammenfassung

- Wählt Testfälle durch Betrachtung der Spezifikation (Schnittstelle) der Komponente
  - Ein Testfall für jedes verschiedenartige Verhalten
  - z.B. Standardfälle, Fehlerfälle, Randfälle
- Verlangt oft erhebliche Kreativität und Urteilskraft
  - Es ist nicht klar, was alles als "verschiedenartig" gelten sollte
- Gut: Verlangt Nachdenken über das Sollverhalten
  - Sehr oft liegt keine ausreichende Spezifikation vor
- Oft kombinatorische Explosion der Fälle
  - Beschränkung auf wichtigste Fälle nötig

Äh, wo waren wir doch gleich?

Analytische Qualitätssicherung

- Dynamische Verfahren (Test)
  - Defekttest
    - Wie wählt man Zustände und Eingaben aus?
      - Funktionstest (*black box test*)
      - **Strukturtest (*white box test, glass box test*)**

Strukturtest (structural test, white box test)

- Wählt Testfälle durch Betrachtung der Implementation (Struktur) der Komponente
  - Man "guckt also in die Komponente rein", deshalb *white box test* (oder treffender: *glass box test*)
    - als Gegensatz zu *black box test*

- Ziel: Abdeckung aller Elemente der Implementation durch die Summe der Testfälle
  - Was heißt "Abdeckung"?
  - Was heißt "Element"?

Abdeckungskriterien

Arten von Abdeckung (Überdeckung, coverage):

- **Anweisungsüberdeckung** (statement coverage, C_0)
  - Jede Anweisung wurde mindestens einmal ausgeführt
    - schwächstes Kriterium
    - aber häufigstes in der Praxis eingesetztes Kriterium
  - Für Fehlerbehandlungscode meist schwierig, evtl. unmöglich
- **Bedingungsüberdeckung** (condition coverage, C_1)
  - Zusätzlich: Jede Steuerbedingung (bei if, while, switch etc.) war mindestens einmal falsch und einmal wahr
- **Schleifenüberdeckung** (loop coverage, manchmal C_2)
  - Zusätzlich: Jede Schleife wird einmal 0-fach, einmal 1-fach und einmal mehrfach durchlaufen
- **Datenflusskriterien**
  - Viele verschiedene Kriterien der Art: "Jedes Beschreiben einer Variable wird auch später mal ausgelesen/benutzt"
    - mächtig, aber wenig praktikabel und schwierig anzuwenden

Strukturtest: triviale Beispiele

- 7 Anweisungen (3 if, 3 Zuweisg., 1 assert)
  3 Bedingungen
- Bestmögliche Anweisungsüberdeckung ist 86% (6 von 7)
  - denn das *assert* ist nicht erreichbar
    - (mit float geht es: NaN)
- 3 Testfälle nötig, z.B.: $x \in \{2, -5, 0\}$

```
if (x > 0)
        result = 1;
else if (x < 0)
        result = -1;
else if (x == 0)
        result = 0;
else
        assert false;
```

- 5 Anweisungen (2 if, 3 Zuweisungen)
  2 Bedingungen
- Bestmögliche Anweisungs- (C_0) und Bedingungsüberdeckung (C_1) ist 100%
- Nur 2 Testfälle nötig, z.B.: $x \in \{-3, 0\}$

```
if (x < 0)
        result = -1;
else
        result = 1;
if (x == 0)
        result = 0;
```

Abdeckungsmessung durch Werkzeuge

- Bei komplexer Logik kann man die Abdeckung nicht mehr gezielt konstruieren
- Entsprechende Werkzeuge messen zur Laufzeit die Abdeckung der Tests
  - (meist nur die Anweisungs-überdeckung)
  - und zeigen Übersichten an.
- Testfälle zum Schließen der Lücken muss man sich meist selbst ausdenken
  - Obwohl es auch längst Werkzeuge gibt, die dabei helfen können

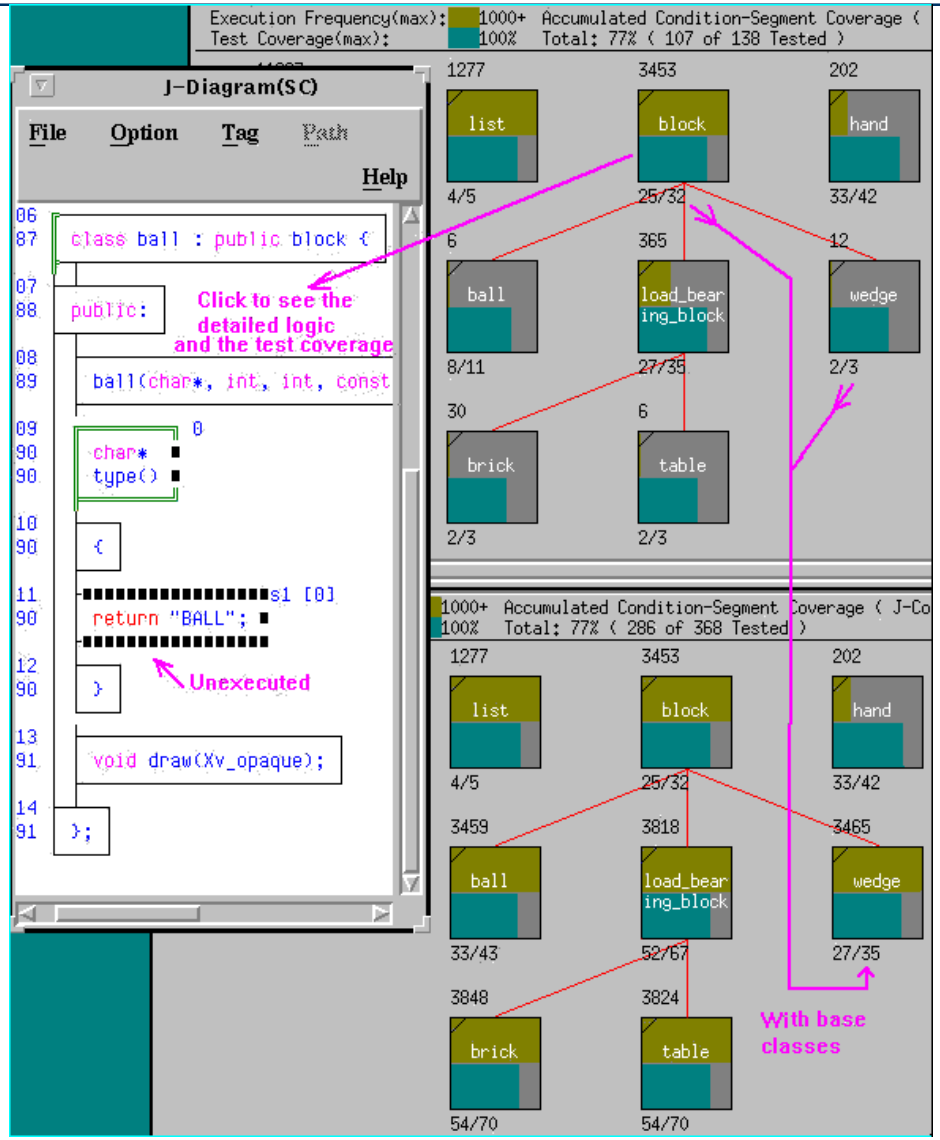

Besonderheit bei objektorientierten Programmen

Freie Universität Berlin

- Kontrollfluss ist bei OO nicht mehr direkt aus Quelltext erkennbar:
  - Ein Aufruf myobj.mymeth() kann auf viele verschiedene Methodenrümpfe mymeth() verweisen
  - Je nachdem, zu welcher Unterklasse myobj gerade gehört

- Konsequenz: Nach Einführung einer neuen Unterklasse müssen alle Programmteile neu getestet werden, die Variablen der Oberklasse evtl. mit Exemplaren dieser Unterklasse verwenden
- Kann im Einzelfall furchtbar kompliziert werden
- Nur durch disziplinierten Entwurfsstil zu lösen:
  - Entwurf per Vertrag (Design by contract): Auch Unterklassen müssen den einhalten.
    - Liskov Substitution Principle. Sehr wertvolle Idee.
  - Gründlicher Modultest gegen diesen Vertrag

!

Wie wählt man Zustände und Eingaben aus?

Freie Universität Berlin

Vorgehensweisen:

- Funktionstest (*functional test, black box test*)
- Strukturtest (*structural test, white box test*)
- **Bekannte Versagensfälle**
- **Allgemeine Erfahrung, Intuition**

Bekannte Versagensfälle

- Wird ein Versagen im Test nicht aufgedeckt
  - sondern erst später,

  wird genau dieser Fall (falls reproduzierbar) nach der Korrektur in jedem Fall getestet

- Evtl. wird dieser Testfall automatisiert und seine Durchführung künftig nach jeder Änderung wiederholt

Allgemeine Erfahrung, Intuition

- Jemand mit genug Testerfahrung "riecht" vielversprechende Testfälle
  - Solcher Intuition sollte man folgen: Oft viel effektiver als schematische Anwendung von Regeln

- Außerdem gibt es ein paar oft anwendbare Faustregeln:
  - Leere Eingaben
  - Riesige Eingaben
  - Völlig unsinnige Eingaben
    - z.B. Binärdaten statt Text; irrwitzige Reihenfolgen von Operationen; etc. (Bei massenhaften Zufallsdaten genannt "fuzzing")
  - Verschachtelte Fehlersituationen
    - Falscheingabe in der Falscheingabe, beim Programmabbruch etc.
  - und andere je nach Domäne

Wer wählt Zustände und Eingaben aus?

1. Jemand, der/die darin geschult ist
2. Möglichst nicht der/die Entwickler/in des Codes

- Psychologische Gründe sprechen gegen Test nur durch Code-Entwickler/in:
  1. Man weist sich ungern selbst seine Unzulänglichkeit nach
  2. Bei Fehlverständnis der Spezifikation enthielten ggf. Code und Tests die selben falschen Annahmen
- Ausnahme: Test-First-Entwicklung (TDD, test-driven devel.)
  - Entwickle und implementiere zuerst die Testfälle, *dann* den Code
  - Geht der psychologischen Abneigung aus dem Weg
  - Verwendet Testfallentwicklung zur Vertiefung des Verständnisses der Spezifikation (oder überhaupt zur/als Aufstellung der Spezif.)
- Ein *paar* Entwicklertests sind stets empfehlenswert
  - Fürs Gröbste, denn die Kommunikation von Versagen zurück an Entwickler/innen ist aufwändig und fehlerträchtig.

Defekttest: Teilprobleme

- Wie wählt man Zustände und Eingaben aus?
- Wer wählt Zustände und Eingaben aus?
- **Wie wählt man Testgegenstände aus?**
- Wie ermittelt man das erwartete Verhalten?
- Wann wiederholt man Tests?
- Wann/wie kann und sollte man Tests automatisieren?
- Wann kann/sollte man mit dem Testen aufhören?

Wie wählt man Testgegenstände aus?

Freie Universität Berlin

- Man sollte keinesfalls gleich das ganze System auf einmal testen (*Big-Bang-Test*)
  - z.B. weil erst kleine Teile davon fertig sind
    - (man sollte aber mit dem Testen so früh wie möglich anfangen)
  - z.B. weil das Lokalisieren der Defekte dann viel zu schwierig wäre
- sondern mit wenigen Teilen anfangen und dann schrittweise mehr zusammenfügen.

3 Möglichkeiten:

- Reines Modultesten (unit testing)
- Bottom-Up-Integrationstesten
  - Fange mit den Teilen an, die keine anderen Teile voraussetzen
- Top-Down-Integrationstesten
  - Fange beim "Hauptprogramm" an

Reines Modultesten ("unit testing")

Freie Universität Berlin

- Jedes Modul wird separat getestet
  - und dafür nötigenfalls von anderen Modulen isoliert
- Vorteil: Debugging im Versagensfall ist einfach
- Nachteile:
  - Wo andere Module benutzt werden, muss man für die Isolation Stummel (stubs, dummies, mock-ups) schreiben
    - und bei Schnittstellenänderungen pflegen
  - Deren Semantik könnte vom Original abweichen
    - Defekte können verborgen bleiben
    - Scheindefekte können auftreten
      - und Verschlechtbesserungen nach sich ziehen
    - Verwirrend!

Bottom-Up-Testen

- Teste stets nur Module/Komponenten, für die alles, was sie aufrufen, schon verfügbar und getestet ist
  - Test beginnt also mit den elementaren Modulen, die nichts anderes aufrufen
- Vorteil: Wir testen nur "reale" und relevante Sachen
- Nachteil: Wir müssen Testtreiber schreiben
- Häufigstes Vorgehen bei gründlichem Test
- Praktikabel

Bottom-up, triviales Beispiel: Audioplayer

(stark vereinfacht)

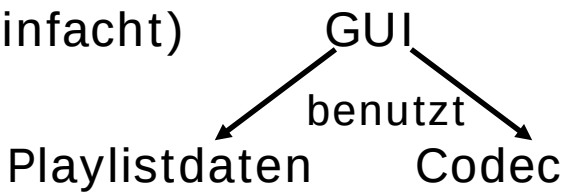

- 1. Teste Codec
  - Treiber für Laden, Start, etc.
- 2. Teste Playlist
  - Treiber für Einfügen, Löschen, Nächster, Listeabrufen etc.
- 3. Teste evtl. GUI ohne Playlist (GUI + Codec)
  - (ohne Treiber): Start, Stopp, Pause, Weiter, Lautstärke, Balance
- 4. Teste Player komplett (GUI + Codec + Playlist)
  - (ohne Treiber): Alle Funktionen

Top-Down-Testen

- Teste stets nur Komponenten, für die keine Treiber nötig sind, weil alles, was sie aufruft, schon verfügbar und getestet ist
  - Test beginnt also mit dem "Hauptprogramm", z.B. der Benutzungsschnittstelle
- Vorteil: Wir testen anschauliche und relevante Sachen
- Nachteile: wie beim Modultest
- Nur sinnvoll, wenn der Entwurf stark in Top-Down-Reihenfolge erfolgt
  - z.B. weil die Anforderungen nur dadurch zu klären sind

Top-down, triviales Beispiel: Audioplayer

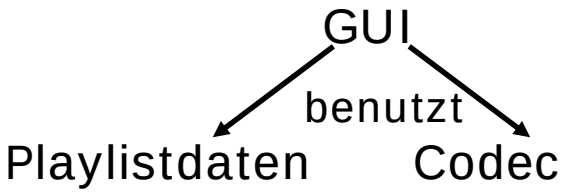

- 1. Teste GUI
  - Stummel für Codec: macht Bildschirmausgaben wie "Starte Wiedergabe von Song X", "Pause", etc.
  - Stummel für Playlist: fast so kompliziert wie das echte Modul!
- 2. Teste GUI mit echter Playlist
  - Stummel für Codec bleibt im Einsatz
- 3. Teste Player komplett (GUI + Codec + Playlist)

Opportunistisches Vorgehen

- In der Realität geht man selten streng nach Bottom-Up- und noch weniger nach Top-Down-Reihenfolge vor
- Statt dessen weicht man ab, wo und wie das praktisch und angemessen erscheint (zumal bei inkrementeller Entwicklung)
  - (Siehe das Top-Down-Beispiel eben: In Wirklichkeit würde man nie einen Stummel für das Modul Playlistdaten schreiben
  - denn der wäre kaum einfacher als das Modul selbst
  - also entwickeln wir das zuerst, testen es Bottom-Up und setzen es dann gleich im Top-Down-Test 1 mit ein.)

- Dabei spielen Testprioritäten eine große Rolle:

Prioritäten beim Testen

Freie Universität Berlin

Überlegungen zur Wahl der Testgegenstände:

- Teile in folgenden Fällen besonders früh testen
  - hat viele Aufrufer (Fehlen behindert weitere Entwicklung stark)
  - hat hohe Risiken für andere Teile
    - Unsicherheiten bei den Anforderungen
    - Auswirkungen auf Architektur (z.B. wegen Effizienz)
- Teile in folgenden Fällen besonders intensiv testen
  - hat viele Aufrufer im System oder
    Funktionalität ist für Benutzer sehr wichtig (z.B. ständig benutzt)
  - Spezifikation ist sehr komplex oder
    Versagen ist schwer zu bemerken
  - Sonstwie kritisch
- Ziel ist stets:
  - Möglichst alle Mängel schon im Komponententest aufdecken,
  - weil es später viel schwieriger wird, das Versagen zu lokalisieren

Defekttest: Teilprobleme

- Wie wählt man Zustände und Eingaben aus?
- Wer wählt Zustände und Eingaben aus?
- Wie wählt man Testgegenstände aus?
- **Wie ermittelt man das erwartete Verhalten?**
- Wann wiederholt man Tests?
- Wann/wie kann und sollte man Tests automatisieren?
- Wann kann/sollte man mit dem Testen aufhören?

Wie ermittelt man das erwartete Verhalten?

Freie Universität Berlin

- Oft ist das "erwartete Verhalten" für einen Testfall nur mit viel Aufwand zu bestimmen
  - deshalb schreibt man ja schließlich eine Software!
- Mögliche Gründe:
  - Komplizierte Eingaben/Fallunterscheidungen (z.B. Bilanzierung),
  - viele Iterationsschritte (z.B. Optimierungsverfahren)
  - viele mitwirkende Systembestandteile (z.B. verteiltes System)
  - Verhalten physischer Systemteile nur ungenau bekannt (cyber-physical systems)

Lösungsansätze:

- Referenzsystem
- Orakel
- Plausibilitätsprüfung
- Notfalls: Manuelle Bestimmung

Erwartetes Verhalten: Referenzsystem

- Manchmal ist eine andere Software verfügbar, die als Vergleich dienen kann
- Beispiele:
  - Altsystem
    - z.B. bei Ersatz eines betrieblichen Informationssystems (etwa wegen Technologiewechsel)
  - System der Konkurrenz
    - bei manchen Arten von Standardsoftware (z.B. bei Systemsoftware)
  - Referenzimplementierung eines Standards
    - z.B. in der Java-Welt, W3C-Welt u.a.
  - Frühere Versionen derselben Software
    - falls dies keine Erstentwicklung ist

- In allen Fällen gilt: Nobody's perfect (auch nicht ein Referenzsystem)
  - Also Vorsicht, nicht zu sehr drauf verlassen

Erwartetes Verhalten: Orakel

- Orakel: Ein Programm, das die Ausgaben eines anderen Programms als *korrekt* oder *falsch* beurteilt

- Manchmal einfacher herzustellen als die Lösung selbst:
  - z.B. bei Gleichungslöser:
    - Ausgabe in die Gleichung einsetzen und gucken ob sie aufgeht
    - Analog bei vielen Arten von Lösern (KI, Robotik etc.)
  - z.B. bei verlustfreier Kompression:
    - Getestete Dekompression anwenden und mit Original vergleichen
      - Dekompression ist oft einfacher!
    - Verlusthafte Kompression ist ein ganz anderes Thema…

Erwartetes Verhalten: Teil-Orakel

- Manchmal lassen sich Orakel finden, die nicht für alle Eingaben oder Verhalten funktionieren

- z.B. für Programm, das Prozessverklemmungen erkennt
  - Orakel prüft, ob erkannte Verklemmung wirklich eine war
  - Orakel kann nicht urteilen, falls keine Verklemmung angezeigt wird

Erwartetes Verhalten: Plausibilitätsprüfung

- Richtige Orakel hat man nur selten zur Verfügung
- Annäherungen an Orakel sind aber oft gut machbar:
  - z.B. bei Sortierverfahren:
    - prüfe, ob Ergebnis sortiert ist und richtige Länge hat
  - z.B. bei Optimierungsverfahren:
    - prüfe, ob Ausgabe eine gültige Lösung ist (aber evtl. nicht optimal)
  - z.B. bei Buchhaltung:
    - prüfe Geldmengenerhaltung (aber vielleicht falsch zugeordnet)
  - z.B. bei GUIs:
    - prüfe, ob gewisse einzelne Elemente den erwarteten Zustand haben
- Allgemein: Prüfe Invarianten, Konsistenzbedingungen, Minimalanforderungen, bekannte Einzelheiten etc.
  - Was halt geht.
  - Kreativität ist gefragt!

Defekttest: Teilprobleme

- Wie wählt man Zustände und Eingaben aus?
- Wer wählt Zustände und Eingaben aus?
- Wie wählt man Testgegenstände aus?
- Wie ermittelt man das erwartete Verhalten?
- **Wann wiederholt man Tests?**
- Wann/wie kann und sollte man Tests automatisieren?
- Wann kann/sollte man mit dem Testen aufhören?

Wann wiederholt man Tests?

Faustregel: Immer, wenn man die Komponente verändert hat

- Das ist bei manuellen Tests, speziell auf Gesamtsystemebene, jedoch sehr aufwändig
  - Aufwand schon bei mäßig großen Systemen z.B. 10 Personen für 2 Monate → über EUR 100.000
  - Das kann man nicht für jede kleine Änderung investieren
  - zumal man ja dann nach jedem gefundenen Fehler von vorn beginnen müsste…
- Sparsamere Regeln:
  - Wiederhole grundlegende Testfälle ("smoke test")
  - Wiederhole Tests, die direkt auf die geänderten Funktionen zielen
  - Wiederhole Tests, die auf Daten zielen, die von den geänderten Funktionen verändert wurden
- **Sehr wichtige und schwierige Fragestellung!**
  - Erfahrene Tester haben hier viel spezifisches Wissen über "ihr" System

Defekttest: Teilprobleme

- Wie wählt man Zustände und Eingaben aus?
- Wer wählt Zustände und Eingaben aus?
- Wie wählt man Testgegenstände aus?
- Wie ermittelt man das erwartete Verhalten?
- Wann wiederholt man Tests?
- **Wann / wie kann und sollte man Tests automatisieren?**
- Wann kann/sollte man mit dem Testen aufhören?

Wann/wie kann und sollte man Tests automatisieren?

Freie Universität Berlin

Was ist Testautomatisierung?

- Testen umfasst:
  1. Testfall auswählen
  2. Testfall durchführen
  3. Ergebnis(se) prüfen
  4. Erfolg oder Versagen feststellen

- Testautomatisierung bedeutet, einen oder mehrere dieser Schritte programmgesteuert auszuführen:
  1. Testeingabe erzeugen
  2. Testeingabe abarbeiten
  3. Ergebnisse überprüfen
  4. Resultat protokollieren und ggf. Versagen anzeigen

(Meist meint das Wort heute die Schritte 2+3+4, aber nicht 1)

Warum Testautomatisierung?

Freie Universität Berlin

- **Mehr Testen:**
  Manuelles Testen kann immer nur einen winzigen Teil des Verhaltensraums eines Systems abdecken
  - Vollautomatisiertes Testen kann den Anteil erhöhen
    - wenn auch die Erzeugung der Testfälle (Schritt 1) automatisiert ist

- **Wiederholt Testen:**
  Defekte können auch noch später in die Software eingefügt werden
  - werden also nur gefunden, wenn später erneut getestet wird

- **Zuverlässiger Testen:**
  Manuelles Testen ist seinerseits fehleranfällig
  - Evtl. werden Versagen schlichtweg übersehen

Rückfalltesten (Regressionstesten)

- Automatisiertes Rückfalltesten automatisiert alle Schritte außer der Testfallerzeugung.
  - Testfälle werden (1) manuell implementiert
  - Automatisierung (2) führt aus, (3) prüft Ergebnis und (4) protokolliert
- Sichert Integrität des Systems nach Veränderungen ab
  - Paradebeispiel: Refactoring (siehe Agile Prozesse)
- Probleme:
  1. Das Implementieren/Automatisieren der Testfälle ist aufwendig
     - Vor allem das Prüfen der Resultate
     - Grobe Faustregel: 10x so viel Arbeit wie eine manuelle Durchführung
       - Aber Modul- und Bottom-up-Tests gehen oft kaum manuell
  2. Rückfalltesten ist nur mäßig wirksam
     - Es gäbe oft viel mehr Defekte mit neuen Testfällen zu finden als durch die Wiederholung von alten

Einsatz von Rückfalltesten

1. **Zur Korrektheitsabsicherung von Änderungen**
2. Für Portabilitätstests auf verschiedenen Plattformen
   - Betriebssysteme, Prozessoren, Compiler, DBMS etc.
3. Zum Test verschiedener Systemkonfigurationen
   - Davon gibt es eventuell Millionen…
4. Zur Prüfung der Korrektur gefundener Defekte
   - Testfall wird vor dem Vorliegen der Korrektur implementiert
   - Auch um sicherzustellen, dass sich gleiche Defekte nicht erneut in die Software einschleichen

Sehr wichtige Technik für professionelle SW-Entwicklung!

Fragen zur Amortisationswahrscheinlichkeit

Freie Universität Berlin

Für (+) oder gegen (-) automatisiertes Rückfalltesten spricht:

- \+ Ist die Benutzungsschnittstelle stabil?
- \+ Wird es Nachfolgeversionen des Systems geben?
- \+ Wird es vermutlich Defektkorrekturen geben?
- \+ Ist das Testpersonal des Programmierens mächtig?
- \+ Gehört das Produkt zu einer Familie ähnlicher Produkte?
- \- Sind starke Ergänzungen zum Testwerkzeug nötig?
- \- Ist das Systemverhalten indeterministisch?

Häufige Fehler bei Testautomatisierung

Freie Universität Berlin

- Automatisierungskosten oder Amortisationszeit unterschätzt
- Trainingsbedarf unterschätzt
- Nutzen von Regressionstest überschätzt
- Testen zugunsten von Testautomatisierung vernachlässigt
- Zu viele simple Testfälle automatisiert
- Zu viel mit Aufzeichnen&Abspielen automatisiert
- 100% Automatisierung versucht
- Testtreiber sind nicht entworfen (zu viel quick & dirty); Redundanz statt Wiederverwendung; nicht wartbar
- Testtreiber sind zu spezifisch (Rechnernamen, Bildschirmauflösung, Betriebssystemversion, ...)
- Keine Dokumentation der Teststrategie, Testfälle, Testtreiber oder der einzelnen Testdurchläufe (fehlende Testprotokolle)
- Zu unflexible Testwerkzeuge

Andere Formen der Testautomatisierung

Freie Universität Berlin

Evtl. erfolgversprechender/kosten-nützlicher als Rückfalltest:

- Prüfung von Zusicherungen zur Laufzeit
- Dateneingabetreiber
- Testen mit Ergebnisprüfer
- Lasttest, Leistungstest, Stresstest
- Quick and Dirty
- Testframework

siehe nachfolgende Folien

Prüfung von Zusicherungen zur Laufzeit

Freie Universität Berlin

- Zusicherungen sind Bedingungen, die stets erfüllt sind
  - bzw. sein müssten, wenn das Programm korrekt ist
- Solche Bedingungen kann man in den Programmtext integrieren und zur Laufzeit stets überprüfen
  - d.h. jeder Programmlauf enthält unzählige automatisierte Tests
  - Java: assert
- Arten von Zusicherungen
  - Voraussetzungen (preconditions) von Methoden
  - Effekte (postconditions) von Methoden
  - Invarianten (invariants) von Schleifen oder Datenstrukturen
- Beispiel: *sqrt(x)* prüft postcondition:
  *assert (abs(result*result/x - 1) < 1e-15)*
- Prüfung erfolgt evtl. nur teilweise
  - denn die Prüfung von Quantor-Ausdrücken ist oft zu teuer oder ganz unmöglich

Dateneingabetreiber

- Automatisiert nur die Testfalldurchführung
  - aber insbesondere nicht die Ergebnisprüfung

- Treiber entnimmt Testfälle (Eingabedaten) einer Tabelle o.ä.
  - und schickt sie ans System
- Prüfung der Ergebnisse erfolgt manuell

- Oft viel schneller zu bauen als kompletter Rückfalltest
  - und deshalb evtl. lohnend, selbst wenn man die Testfälle gar nicht wiederholen will
- erleichtert auch manuelle oder halbautom. Protokollführung

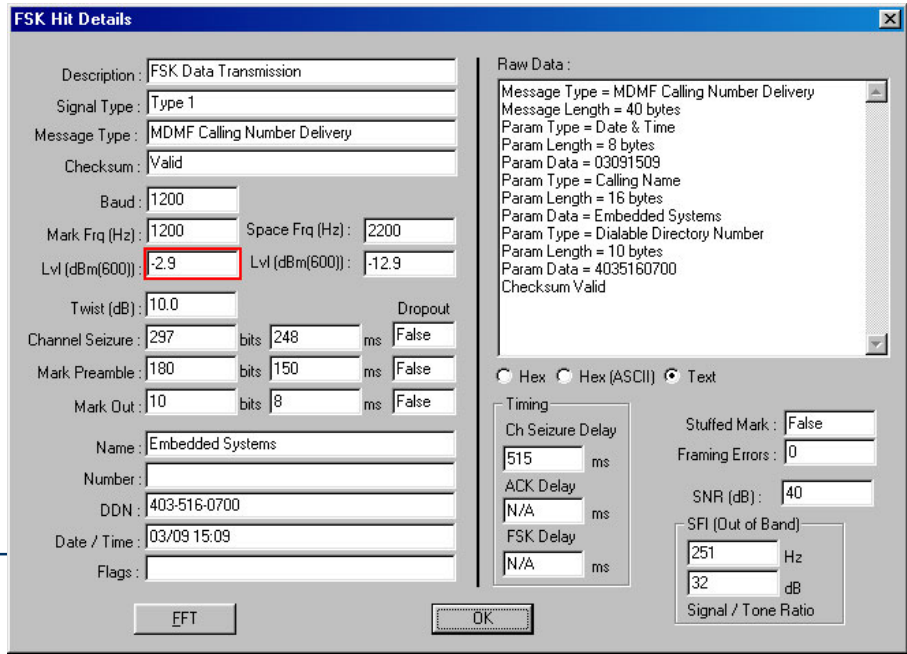

Testen mit Ergebnisprüfer

- Ein Ergebnisprüfer ist ein Programm, das die Korrektheit des Ergebnisses beliebiger Testfälle beurteilen kann
  - implementiert also ein allgemeines Orakel
  - benötigt für vollen Nutzen auch automatisierte Testfallerzeugung (Zufallstest) und Testfalldurchführung
- Vorteil: Extrem hohe Testfallanzahl möglich

Aber: Woher bekommt man einen Ergebnisprüfer?

- Evtl. Referenzimplementierung
  - z.B. Altsystem, Konkurrenzprodukt
- Alte Version des eigenen Produkts
  - entdeckt nicht Versagen, sondern Verhaltensveränderungen
- sonstiges Orakel

Notfalls (besser als nix): Teilorakel, Plausibilitätsprüfung, assert

Lasttest, Leistungstest, Stresstest

- Schickt sehr viele (Lasttest), sehr große (Leistungstest, Stresstest) oder sehr falsche (Stresstest) Eingaben
  - (wie üblich ist die Namensgebung aber uneinheitlich)
- Misst die Abarbeitungsgeschwindigkeit (Lasttest, Leistungstest) oder das ordnungsgemäße Überleben (Stresstest) des Systems

- Sind ohne Automatisierung gar nicht durchführbar

Quick-and-dirty

Definition:

- Jeder Automatisierungsansatz, der etwas effektiv und nützlich automatisiert, aber
- schlecht oder gar nicht entworfen, hastig implementiert, überhaupt nicht dokumentiert ist.

- Voraussetzung: muss extrem kurze Amortisationszeit versprechen (wenige Tage)
  - wird anschließend weggeworfen

- Anwendung z.B. bei der Evaluation von Fremdsoftware
  - z.B. 5 Produkte sind zu prüfen, aber nur 1 wird später benutzt

Übersicht

Analytische QS:

- **Dynamische Verfahren**
  - **Defekttest**
    - **Wie wählt man Zustände und Eingaben aus?**
    - **Wer wählt Zustände und Eingaben aus?**
    - **Wie wählt man Testgegenstände aus?**
    - **Wie ermittelt man das erwartete Verhalten?**
    - **Wann wiederholt man Tests?**
    - **Wann / wie kann und sollte man Tests automatisieren?**
  - Benutzbarkeitstest
  - Lasttest
  - Akzeptanztest
- Statische Verfahren
  - ...

Konstruktive QS:

- Test- und Durchsichtsmgmt.
- Prozessmanagement
- Projektmanagement, Risikomanagement

Danke!