



WINCOR NIXDORF

GI TAV 2011 - Selektiver Regressionstest

Dr. Andreas Wübbeke
Banking Division – Software Development

TUM

TECHNISCHE
UNIVERSITÄT
MÜNCHEN

CQSE

Continuous Quality in Software Engineering

WINCOR
NIXDORF

I **Problemstellung und Projektziele**

II **Stand der Forschung: Selektiver Regressionstest (SRT)**

III **Evaluierung: Möglichkeiten und Grenzen von SRT**

IV **Werkzeugunterstützung**

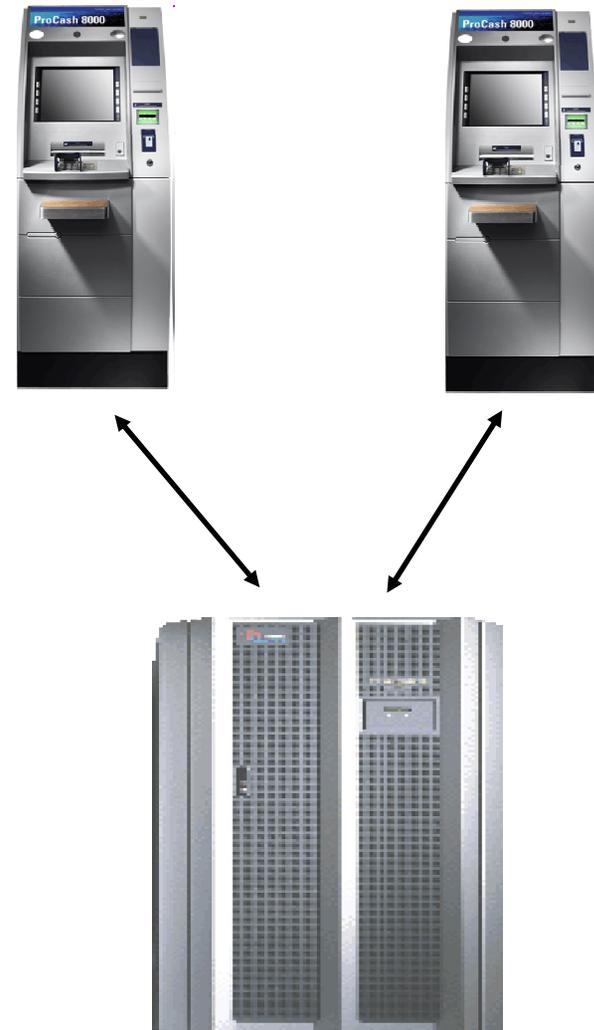
V **Zusammenfassung und Diskussion**

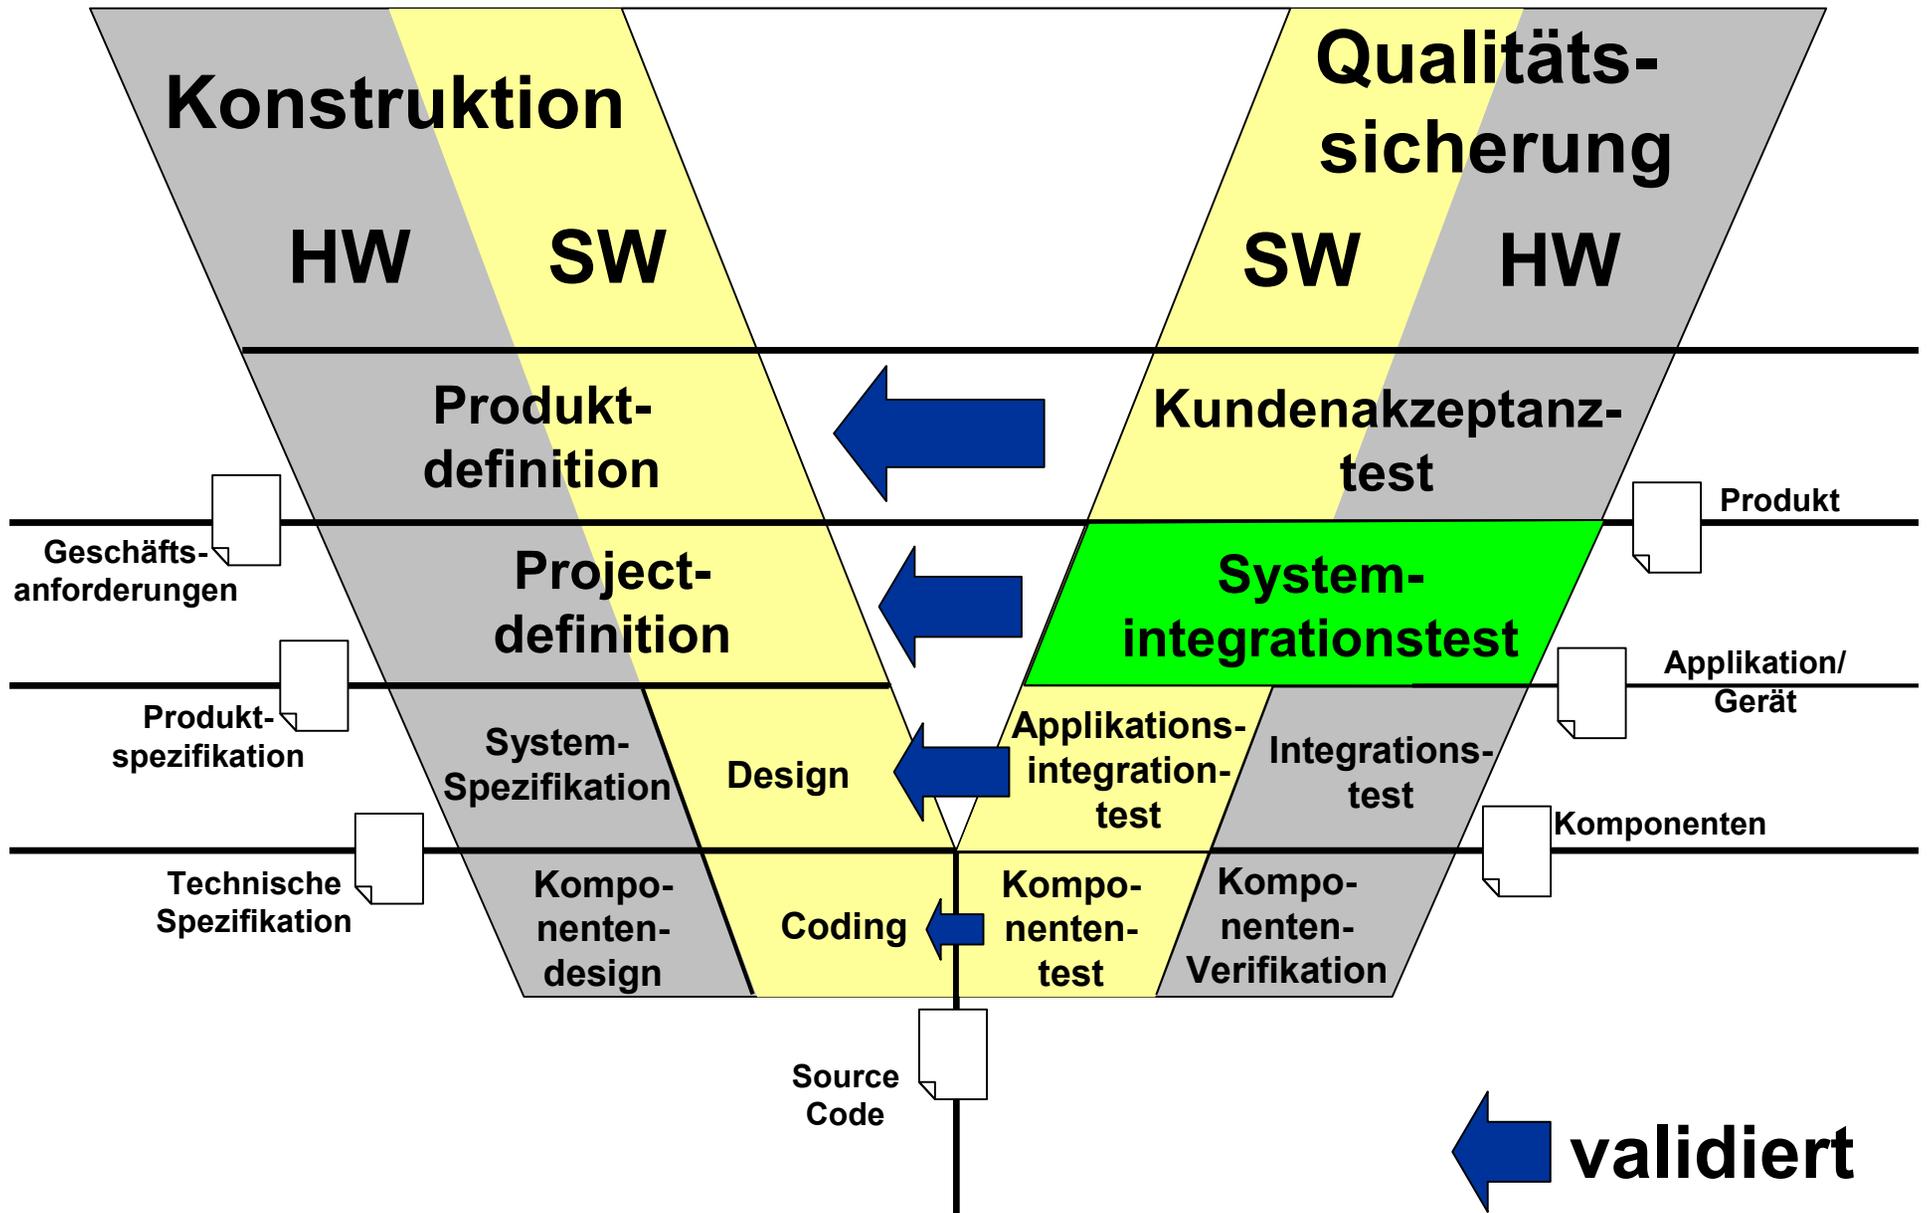
Geldautomaten

- Eingebettetes System
 - mit hoher Variantenvielfalt
 - in heterogenen Systemlandschaften
- Hohe Anforderungen an
 - Sicherheit
 - Robustheit
 - Einfachheit
 - ...

Transaktionsserver

- Informationssystem
 - Verarbeitung von Autorisierung, Transaktionen, Routing
 - Heterogene Systemlandschaften
- Hohe Anforderungen an
 - Sicherheit
 - Robustheit
 - Verfügbarkeit
 - Skalierbarkeit
 - ...



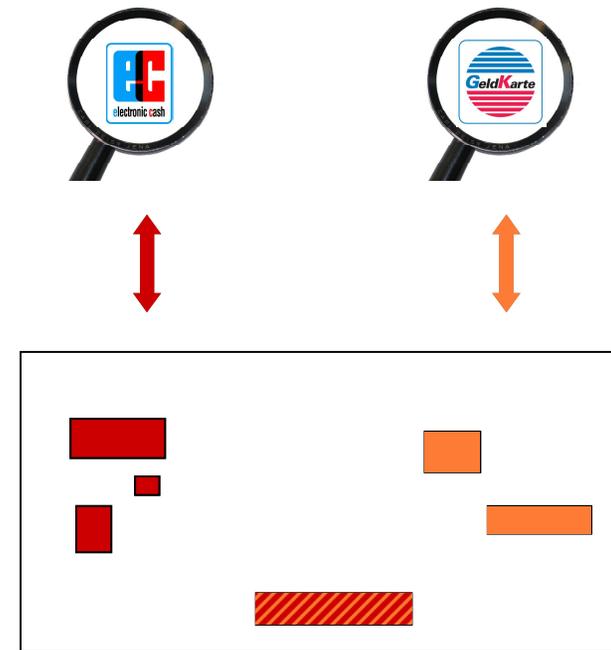


Systemintegrationstest

- Betrachtet das System als Black Box
- Sinnvoll zur Definition funktionaler Tests

Regressionstest

- Spezifikation ändert sich nicht
- Sichert gegenüber unerwünschten Nebeneffekten ab
- Abhängigkeiten im Code können zu Nebeneffekten auf fachlich scheinbar unabhängiger Funktionalität führen
→ Black-Box-Sicht ist nicht ausreichend



Herausforderung

- Auswahl notwendig (Ausführung aller Tests nach Änderung zu teuer)
- Aber: Abhängigkeiten zwischen Code und Testfällen manuell nicht überschaubar

Werkzeugunterstützte Auswahl von Regressionstests

- Evaluierung der Möglichkeiten und Grenzen von Werkzeugunterstützung
- Konzeption und prototypische Realisierung
- Evaluierung bei Wincor Nixdorf

I Problemstellung und Projektziele

II Stand der Forschung: Selektiver Regressionstest (SRT)

III Evaluierung: Möglichkeiten und Grenzen von SRT

IV Werkzeugunterstützung

V Zusammenfassung und Diskussion

Fragestellung: Was mache ich, wenn ich nicht alle Testfälle ausführen kann?

Selektiver Regressionstest (SRT)

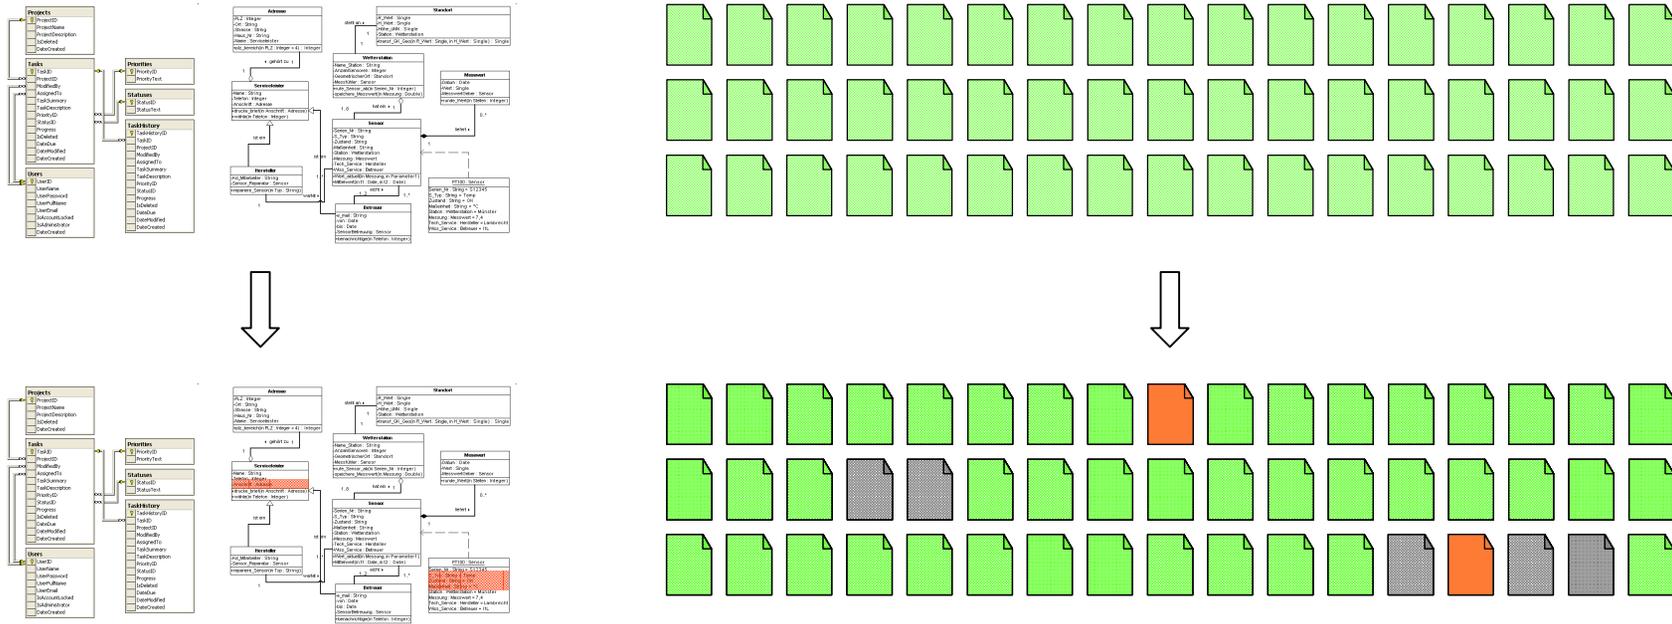
- Wählt Teilmenge der Testfälle bzgl. durchgeführter Modifikationen aus
- ✓ Bietet Einsparungspotential

Testfall-Priorisierung

- Ordnet Testfälle nach Wahrscheinlichkeit Fehler aufzudecken
- Unabhängig von Modifikationen, daher kein Einsparungspotential

Testfall-Reduktion

- Identifiziert redundante Testfälle zur Reduktion der Gesamttestmenge
- Unabhängig von Modifikationen, kein kurzfristiges Einsparungspotential



Ziel

- Ermittlung aller fehleraufdeckenden Testfälle (in Bezug auf Modifikationen)

Ansatz

- Identifikation der modifikations-traversierenden Testfälle

Sichere SRT Verfahren

Fehleraufdeckende Testfälle garantiert in Testmenge

Konservativ (kann zu Überabschätzung führen)

Anwendbarkeit in der Praxis unklar

Heuristische Verfahren

Keine Garantie dass fehleraufdeckende Tests ausgewählt werden

Ermöglichen oft größere Einsparungen (weniger Überabschätzung)

Deutlich bessere Anwendbarkeit

Entwicklungsprozess

Tests vor Modifikation erfolgreich ausgeführt

Umfang der Modifikationen relativ gering

Kontrolle

Außer der Modifikationen wird an der Testumgebung nichts verändert

Abhängigkeiten

Alle Abhängigkeiten zwischen Software-Artefakten sind dem SRT Werkzeug bekannt

(Inklusive: DB Zugriff, Caches, Konfigurationsparameter, ...)

Müssen für sichere SRT Verfahren vollständig erfüllt sein.

Nicht in vollem Umfang für heuristische Verfahren notwendig.

I Problemstellung und Projektziele

II Stand der Forschung: Selektiver Regressionstest (SRT)

III **Evaluierung: Möglichkeiten und Grenzen von SRT**

IV Werkzeugunterstützung

V Zusammenfassung und Diskussion

Zentrale Entscheidungen für Werkzeugprototypen

Sicheres oder heuristisches Verfahren?

Vollautomatischer Ansatz, oder Expertenunterstützung?

Forschungsfragen

**Wie groß ist die Menge an Testfällen, die SRT auswählt
(bzgl. aller Testfälle)**

Wie wirkt sich Unterspezifikation der Testfälle aus?

**Eignen sich Traces zur Vorhersage welche Testfälle modifizierten Code
ausführen werden?**

RQ: Wie groß ist die Menge an Testfällen, die SRT auswählt (bzgl. aller Testfälle)

Vorgehen

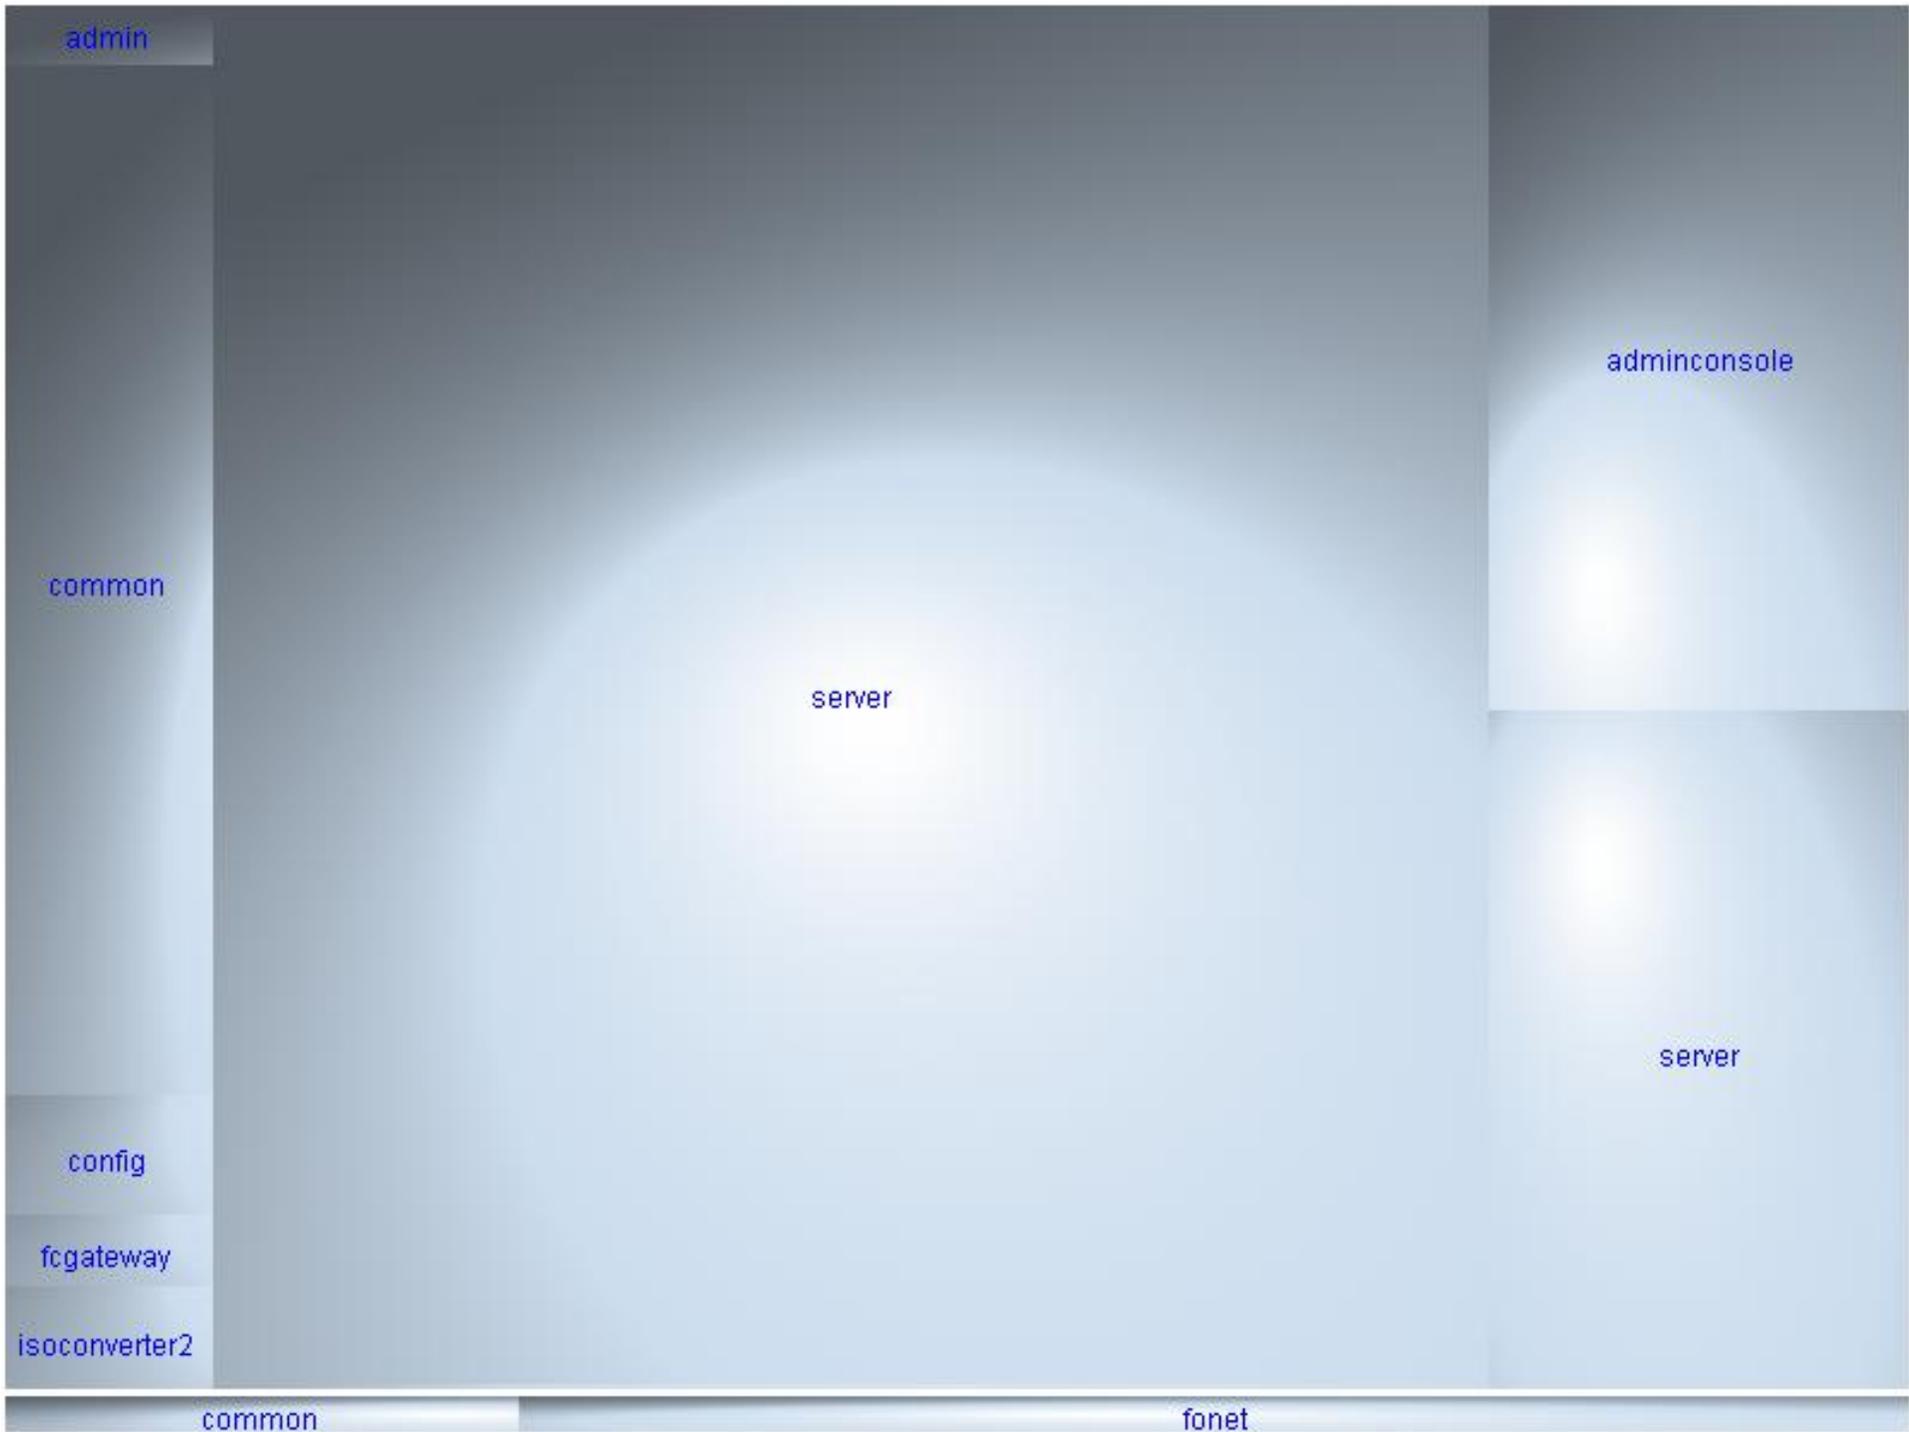
12 Snapshots aus Korrektur-Branch (4157_05 - 4157_16): S_1 bis S_{12}

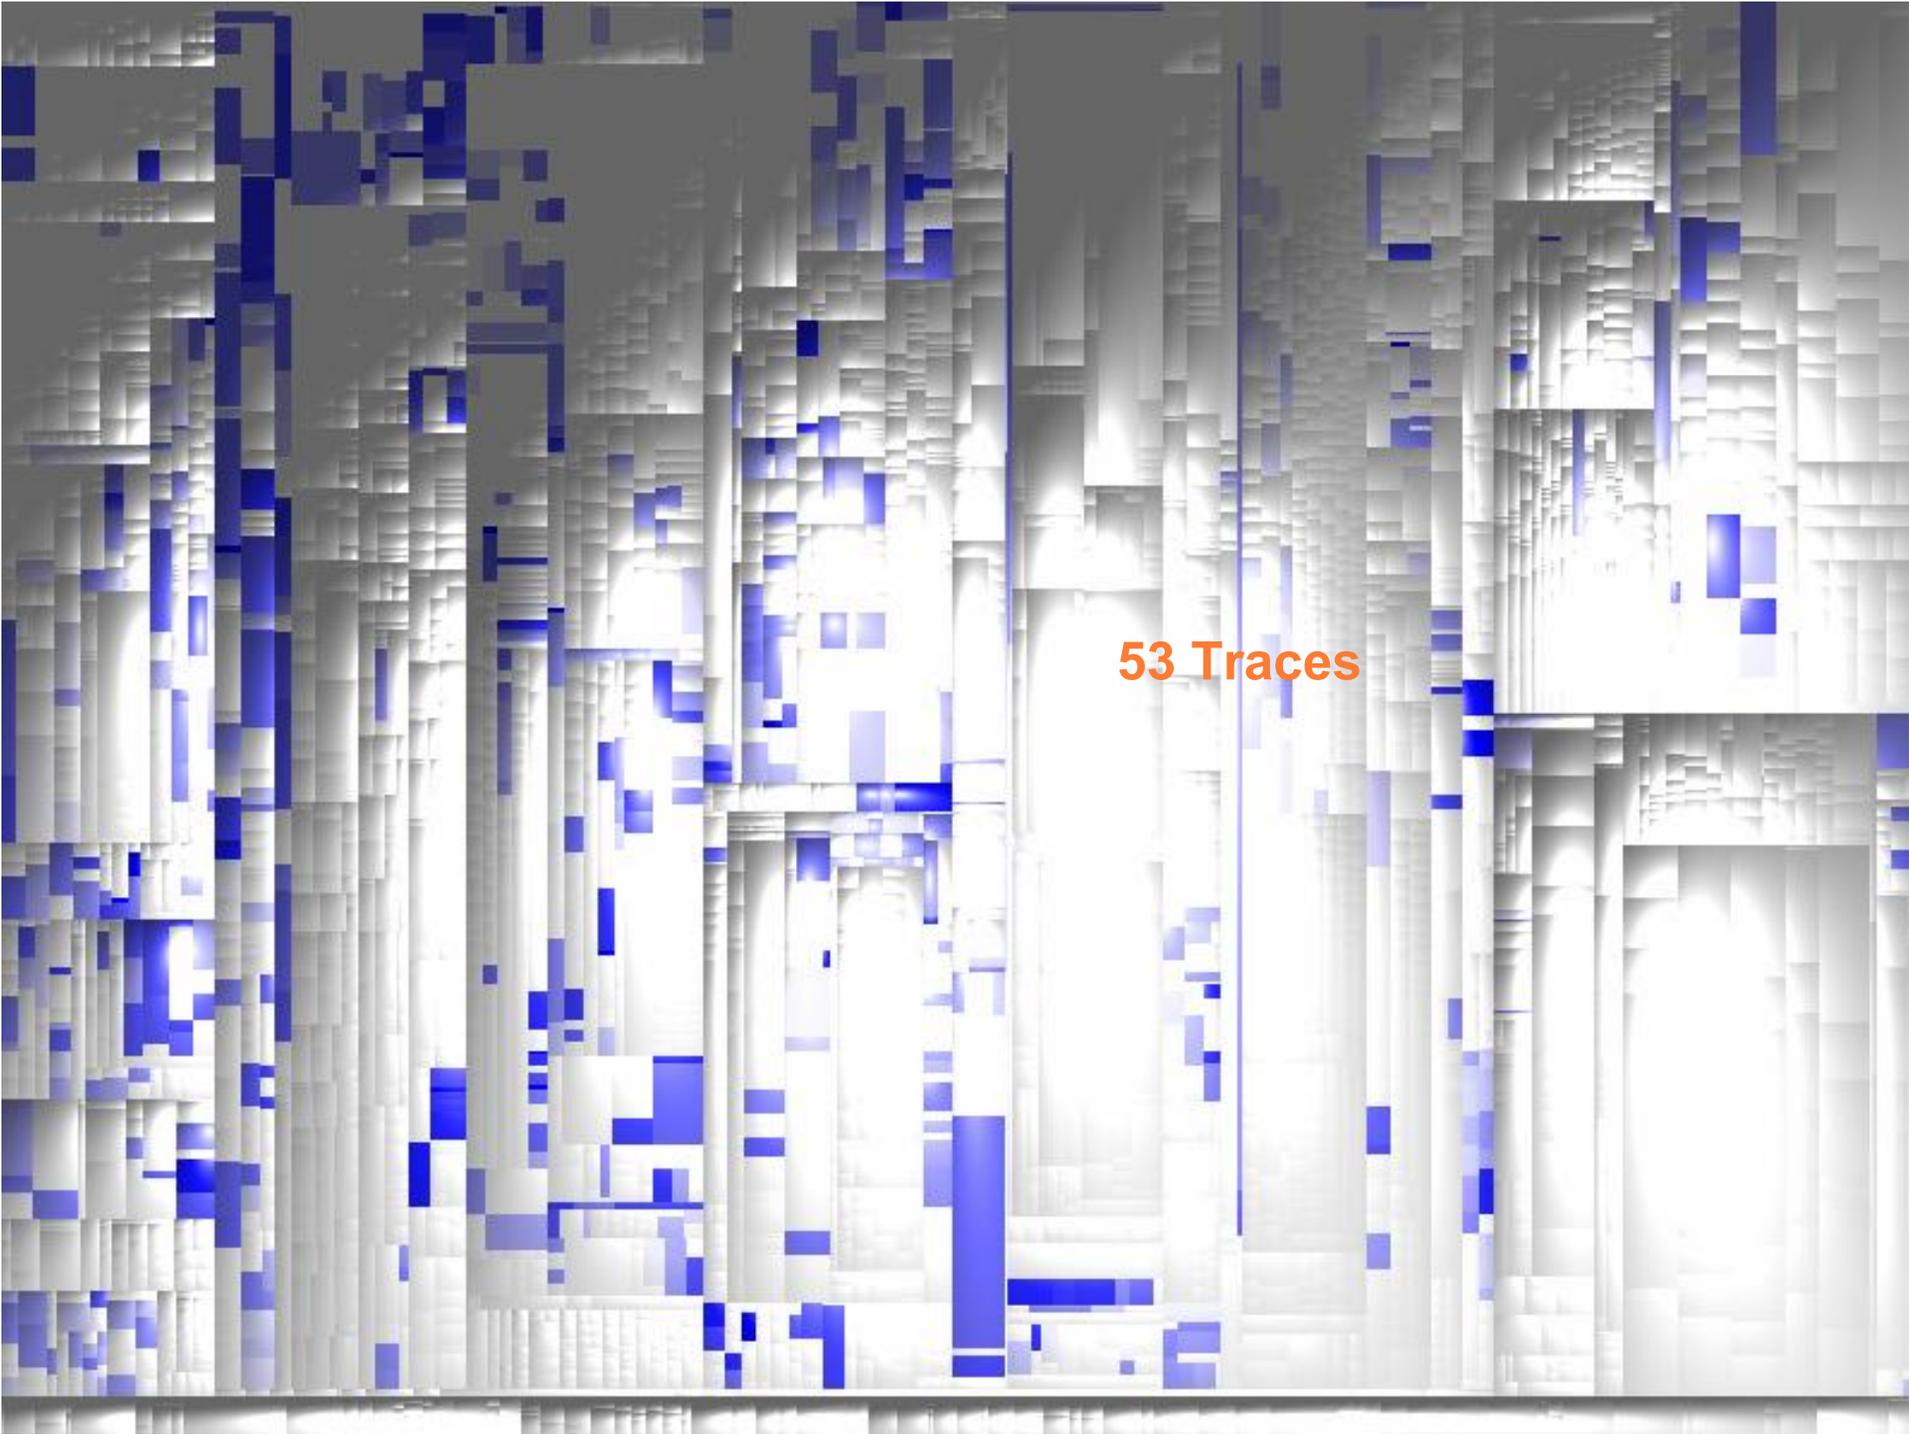
53 Testfälle auf S_1 ausgeführt und Traces aufgezeichnet

Bestimmung der Code-Modifikationen zwischen S_1/S_2 , S_2/S_3 , S_3/S_4 , ...

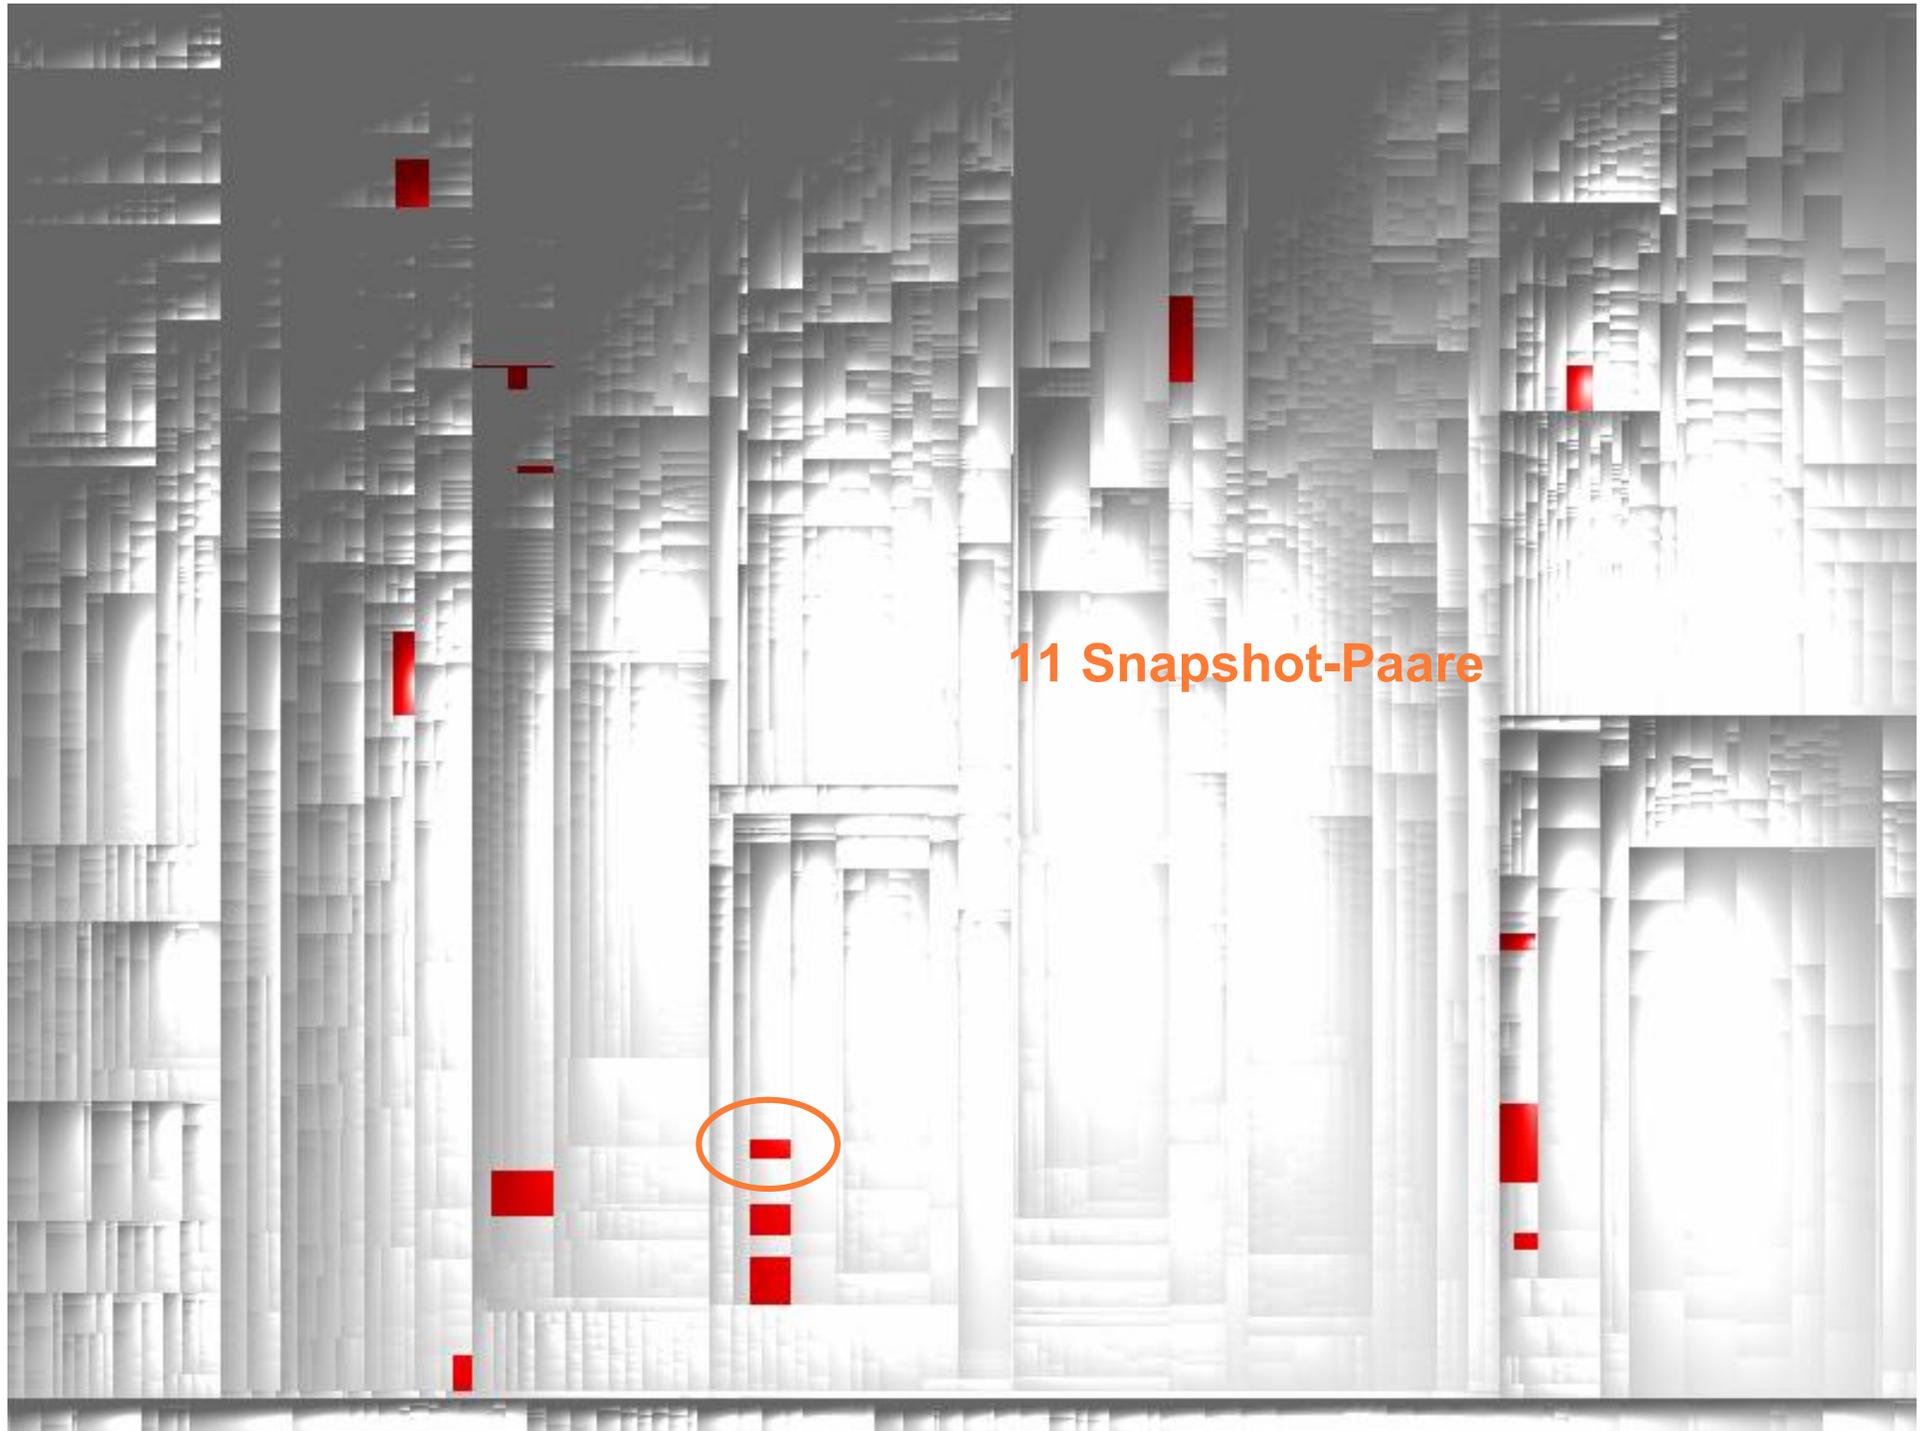
Ermitteln der Anzahl betroffener Testfälle

Ermitteln der Anzahl betroffener Testfälle für zufällig ausgewählte Methoden





53 Traces



11 Snapshot-Paare

Bei S_6 , S_8 und S_9 Änderungen am Code

41/12/30 Methoden geändert,

13/4/2 überdeckt,

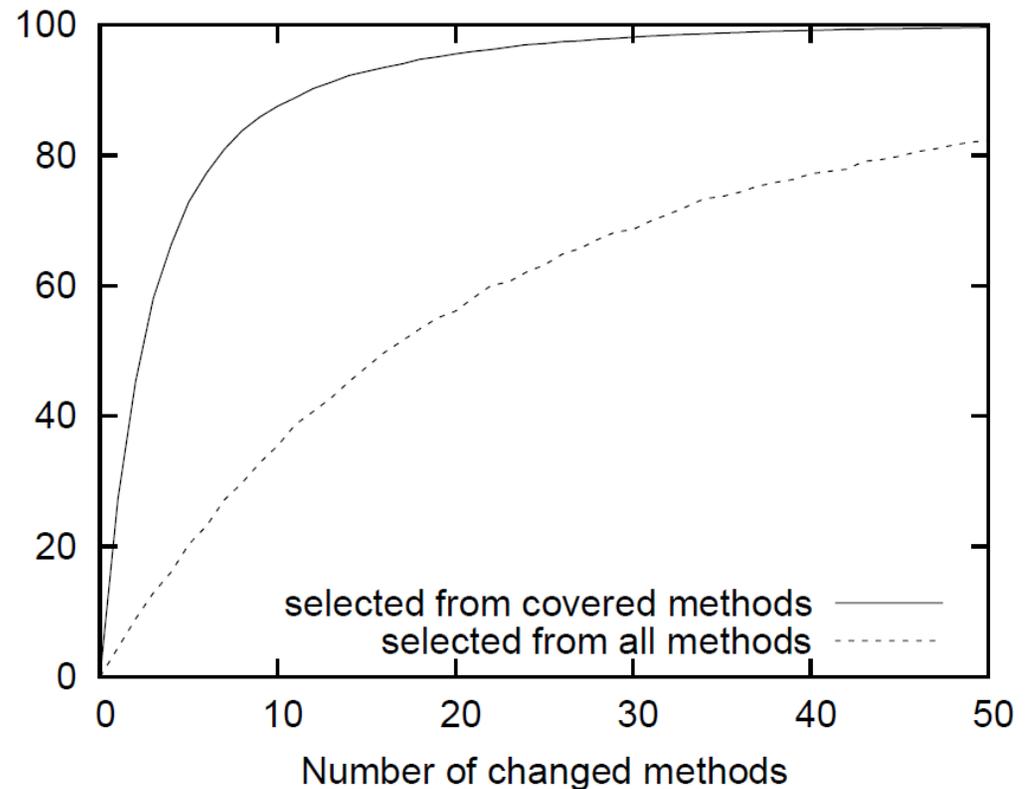
62%/62%/6% Tests betroffen

Allgemeine Änderungen

Zufällige Auswahl von Methoden

Bei 3 geänderten Methoden 50%

der Tests betroffen



RQ: Wie wirkt sich Unterspezifikation der Testfälle aus?

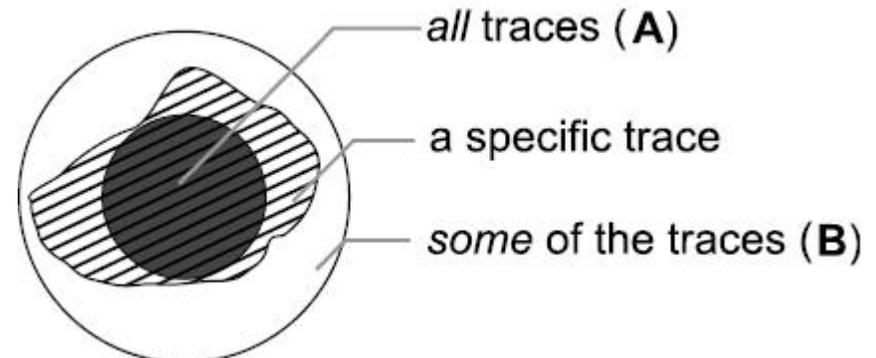
Vorgehen

T_1, T_2, T_3 je 6x auf S_1 getraced
 Jede Ausführung konsistent zu Spec.
 Wieviele Methoden werden immer /
 manchmal durchlaufen?

Ergebnis

Im schlechtesten Fall: nur 1/3 der
 Methoden immer überdeckt

Sichere Verfahren nicht einsetzbar



test case	A	B	$ A /(A + B)$
T_1	3692	325	92%
T_2	4211	314	93%
T_3	1605	3295	33%

Größe der Selektierten Testfallmenge

Schon bei 3 unabhängigen Änderungen >50% der Tests betroffen

Deutlich zu viele für Einsatz während Hotfix

Kein vollautomatischer Ansatz für Werkzeug

Unterspezifikation von Testfällen

Kontroll-Annahme nicht erfüllt.

Ursache: Blackbox / Whitebox Diskrepanz

Vollständige Spezifikation in der Praxis nicht machbar

Kein sicheres Verfahren

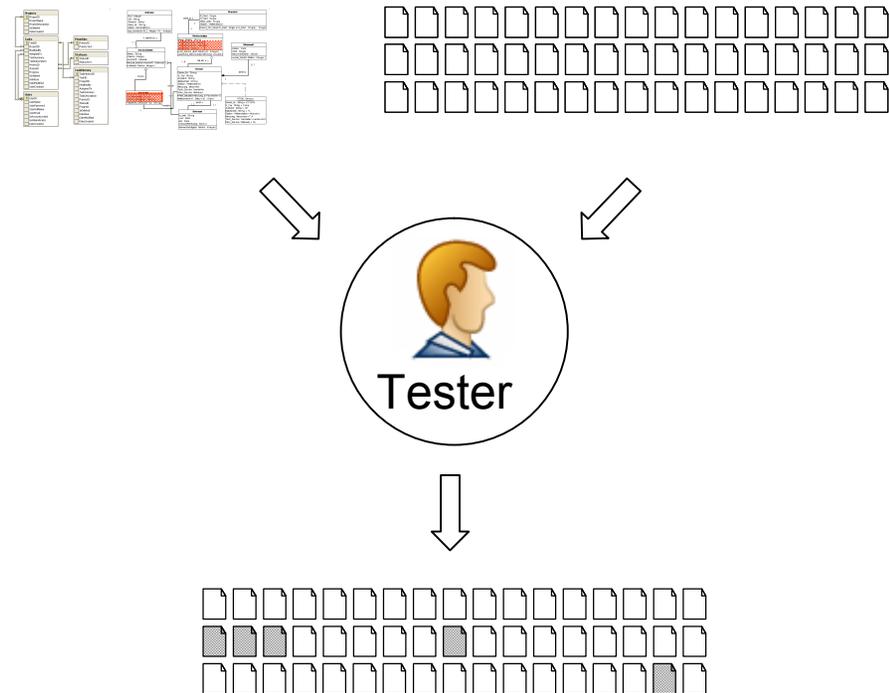
Ausrichtung Werkzeug:

Fokus auf Expertenunterstützung

Einsatz von heuristischen SRT Verfahren

Ermittlung Testfall Kandidaten
Berechnung des Deltas
Ermittlung der Tests, die mit hoher Wahrscheinlichkeit Änderungen durchlaufen

Priorisierung von Kandidaten
Tester inspiziert Delta im Code
Ggf. Rückfragen an Entwickler
Wählt Testfälle aus Kandidaten



Ziel: Verbindung von SRT Werkzeug und Expertenwissen

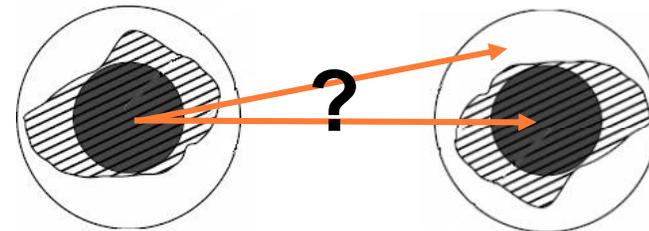
RQ: Wie stabil ist die Methodenüberdeckung über Systemversionen hinweg?

Vorgehen

**T_1, T_2, T_3 je 3x auf S_5 und S_{12} getraced
Jede Ausführung konsistent zu Spec.
Sind stabile Ms aus S_1 weiterhin stabil?**

Ergebnis

**Überdeckung stabil
Geeignet für Testfall Selektion**



	$S_1 \rightarrow S_5$	$S_1 \rightarrow S_{12}$
T_1	99.1%	99.0%
T_2	99.6%	98.5%
T_3	100%	99.9%

I Problemstellung und Projektziele

II Stand der Forschung: Selektiver Regressionstest (SRT)

III Evaluierung: Möglichkeiten und Grenzen von SRT

IV Werkzeugunterstützung

V Zusammenfassung und Diskussion

Programm muss nicht manuell modifiziert werden

Laufzeiten erhöhen sich nicht zu stark

Programmverhalten darf sich nicht ändern

Muss auch in Test-Umgebung funktionieren

Automatische und systematische Modifikation des Programms

- Instrumentierung zur Übersetzungszeit (im Quellcode)
- Byte-Code-Instrumentierung (nach Übersetzung)
- Instrumentierung zur Laufzeit

Aufzeichnung über eine kontrollierte Ausführungsumgebung (Simulation)

- Wird z.B. von Valgrind genutzt

Instrumentierung des Java-Byte-Codes zur Laufzeit

Instrumentierungsschnittstelle: Java Agents

- Unterstützt ab Java 1.5

Vorteile

- Keine Änderungen an Source- und Byte-Code
- Funktioniert auch mit Byte-Code der erst zur Laufzeit erzeugt wird (z.B. AOP)
- Robust in komplexen Umgebungen (mehrere Threads, mehrere Class Loader)
- Aktivierung/Deaktivierung durch „einfachen“ Neustart des Programms

System	#Tests	Zeit ohne Tracing (Sek.)	Zeit mit Tracing (Sek.)	Slow Down
CCSM Commons	417	7,7	13,2	71%
ConQAT Driver	108	1,1	1,2	9%
ConQAT CloneDetective	95	2,0	2,9	45%
ConQAT System Tests	27	260	267	<3%

Wincor-Unit-Tests liefern gleiches Ergebnis mit und ohne Tracer

Zeitmessung der Startphase der PC/E-Prozesses (inkl. WebSphere-Overhead)

System	Normal	Tracer ohne Aufzeichnung	Tracer mit Aufzeichnung
real	54 - 82	57 - 71	56 - 57
user	3,3 - 3,9	3,3 - 4,0	3,0 - 3,7
system	2,2 - 2,5	2,1 - 2,6	2,2 - 2,8

Änderungen am System müssen „robust“ erkannt werden

- Tolerant gegenüber Änderungen der Formatierung/Einrückung
- Tolerant gegenüber Änderungen außerhalb des ausgeführten Codes
 - Kommentare
 - Import-Statements

→ Einfacher Diff reicht nicht

Nutzung eines Parsers um Struktur des Java-Codes zu erkennen
Bestimmung der Unterschiede auf dem AST

Kann mit Formatierung und Kommentaren umgehen
Problematisch: Import-Statements, etc.

Guter Parser für Java schwer zu erstellen/zu finden
Benötigt Typ-Resolution um zuverlässig zu funktionieren

Alternativer Ansatz: Erkennen der Änderungen im Byte-Code

Vorteil: Compiler überführt Code in Normalform

- Tolerant gegenüber Formatierung und Kommentaren
- Import-Statements sind normalisiert
- Tolerant gegenüber Umbenennung von lokalen Variablen und Parametern
- Genau der kompilierte Code wird betrachtet (unabhängig von MKS)

Änderungen werden nur für Methoden betrachtet

- Änderungen an Feldern wirken sich auf (compilierte) Methoden aus die diese Nutzen
- Konstanten werden bei Java inline genutzt (oder in *static initializer* belegt)

→Wichtig: Version und Einstellungen des Compilers können Auswirkungen haben

I Problemstellung und Projektziele

II Stand der Forschung: Selektiver Regressionstest (SRT)

III Evaluierung: Möglichkeiten und Grenzen von SRT

IV Werkzeugunterstützung

V Zusammenfassung und Diskussion

Ausrichtung

Unterstützung von Testern bei Auswahl von Regressionstests

(Kein Ersetzen der Tester durch Tool)

Heuristisches Verfahren, da sichere Verfahren nicht anwendbar für Systemtests

Liefert keine obere Schranke für Testdurchführung

Stand Prototyp

Tracer evaluiert auf PC/E Testumgebung

Differ unabhängig von Source Konfiguration, erfolgreich eingesetzt

Vollständiger Funktionsumfang prototypisch realisiert

Literatur

**Elmar Juergens, Benjamin Hummel, Florian Deissenboeck, Martin Feilkas,
Christian Schlögel, Andreas Wübbeke:**

Regression Test Selection of Manual System Tests in Practice

**To appear in Proc. of 15th European Conference on Software Maintenance and
Reengineering (CSMR'11), 2011.**

Aufzeichnen der Traces

Integration des SRT Werkzeugs in das WN Testmanagementwerkzeug zur Trace Erzeugung?

Ziel: Minimierung der notwendigen Arbeitsschritte für Tester

Aufzeichnen der Snapshots

Import in SRT Tool, wenn neuer Snapshot zum ersten Mal getestet wird

Integration in Prozess zur Installation eines neuen Snapshots im Test?

Anwendung des Werkzeugs

Auswahl von Regressionstestfällen für Hotfixes

Überprüfung der Testabdeckung von neuem Code

Überprüfung der Testabdeckung von Änderungen

(Fokus nicht auf *vollständiger*, sondern auf *bewusster* Überdeckung)

