
https://commons.wikimedia.org/wiki/File:Mutant_Giraffe_(25698457).jpeg

Revival der Mutationstests

Eine sinnvolle Ergänzung selbst für TDD

Dehla Sokenou

49. TAV-Treffen in Gummersbach

Februar 2024

Test- und Qualitätsmanagerin
Software-Architektin

Sprecherin der GI-Fachgruppe TAV

https://www.wps.de/

https://fg-tav.gi.de/

https://dpsq.de/

Ihr macht doch TDD – warum denn noch mehr?

- Der TDD-Zyklus und die Sicherheit…

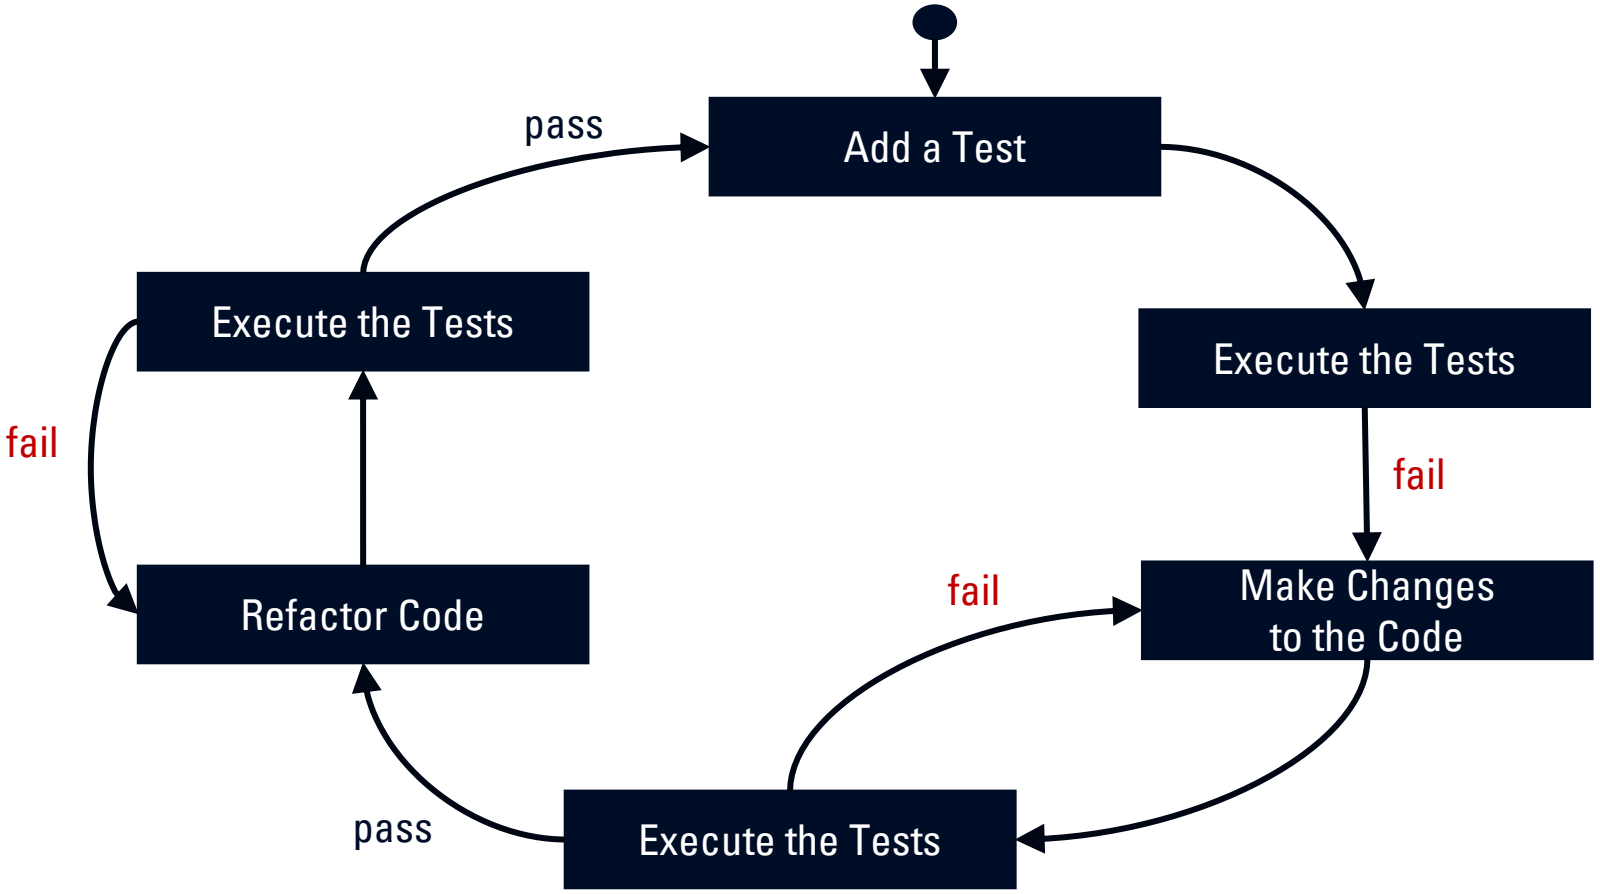

- ABER:
  - Machen wir zu viel?
  - Machen wir das Richtige?

Projekt-Setting

- Langlaufendes (sehr) agiles Projekt
- Backend und Frontend – Microservice-Architektur

- Teamübergreifendes Testkonzept:
  - Management-Vorgabe und Projektziel: > 90% Branch-Coverage
  - Test-Driven Development erwünscht, aber nicht gefordert
    - Aber unter uns: 90% Branch-Coverage ist mit TDD geschenkt ☺
  - Weitere Testaktivitäten u.a. End2End-Tests, Bingo-Bongo-Testsessions, …
  - Mutationstests nach etwa einem halben Jahr Laufzeit eingeführt

Hypothesen

1. The *competent programmer* hypothesis
   - Programmierer implementieren in der Regel (fast) korrekte Programme
   - Kleinere Fehler lassen sich trotzdem nicht vermeiden
2. The *coupling effect* hypothesis
   - Kleinere Fehler im Code können große Probleme verursachen

- Deshalb: Testen!

- ABER:
  - Machen wir zu wenig?
  - Machen wir zu viel?
  - Machen wir das Richtige?

Mutationstests – wie funktioniert es?

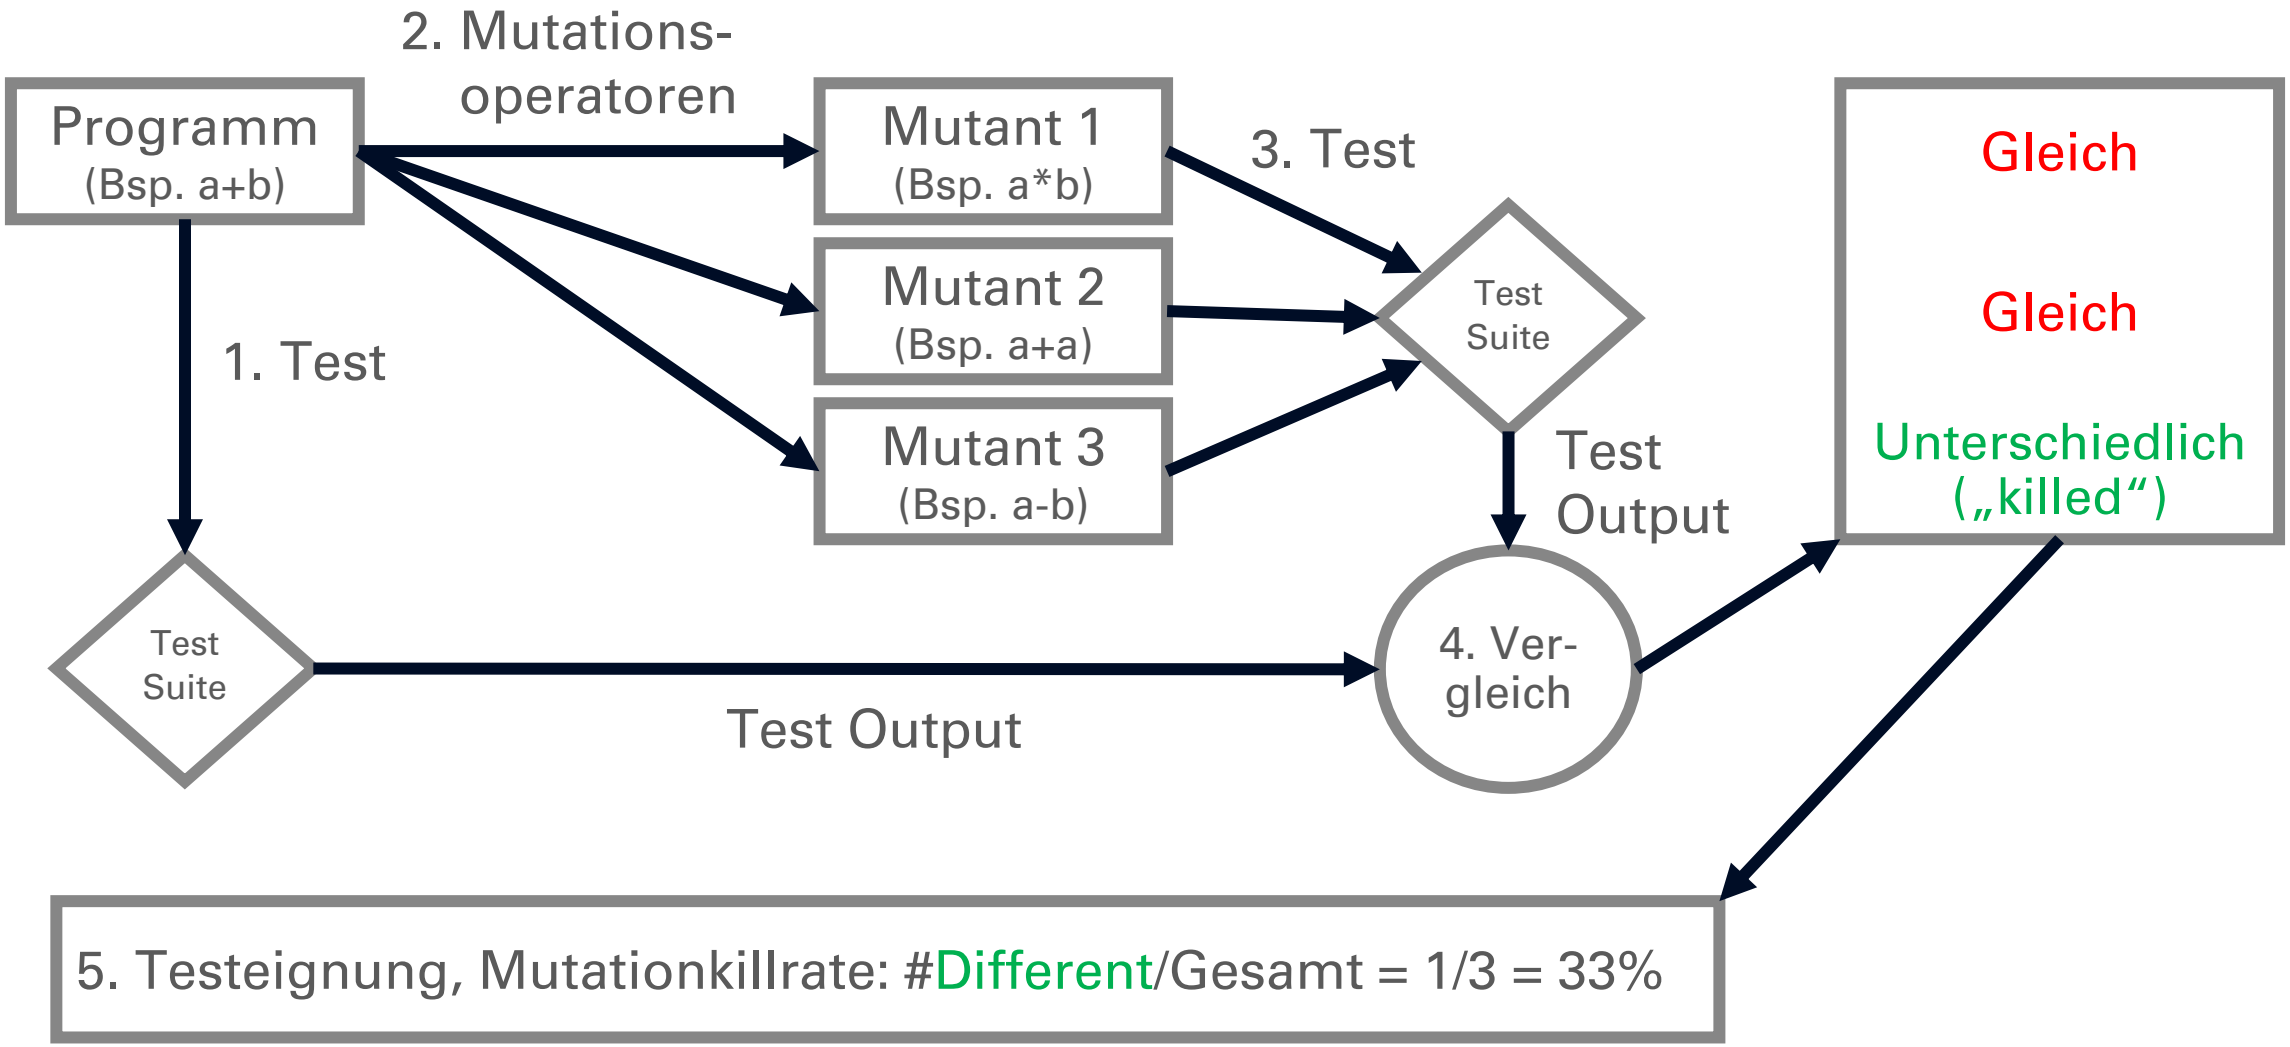

Die Mutanten sind los!

- Mutationen sind typische Programmierfehler oder typische Fallstricke im Code
  - Leere Returns (null, leere Collection statt richtigem Ergebnis)
  - Negation einer Bedingung (true statt false)
  - Änderung einer bool‘schen Operation (> statt >=) oder arithmetischen Operation (+ statt -)
  - Anweisung entfernen oder duplizieren
  - Methodenbody entfernen
  - Variablen vertauschen
- Abhängig von der verwendeten Programmiersprache
  - Beispiel: Annotation entfernen

Ein kleiner Blick in die Historie

Oder: warum ist es inzwischen wieder ein Thema?

- Idee vorgestellt im Jahr 1971 (!) von Richard Lipton
- 1. Implementierung eines Tools von Timothy Budd im Jahr 1980
- Dann war es lange ruhig
  - Da Mutationstests sehr rechenintensiv sind, fehlte lange einfach die Leistung
  - Was erst mal in der Schublade liegt, bleibt oft auch erst einmal dort
- Wiederbelebung erfolgt langsam
  - Seit den 2020ern vermehrt Artikel zu Thema
    - Obwohl es Werkzeuge wie PITest (PIT) schon länger gibt
  - Es reicht ein simples Integrieren in die Pipeline, z.B. als Maven-Plugin / npm-Paket

Test your tests…!

- **Überdeckungsmessung** zeigt Qualität der **ACT**s
  - Habe ich alle Teile meines Source-Codes mit den Tests „getroffen“?

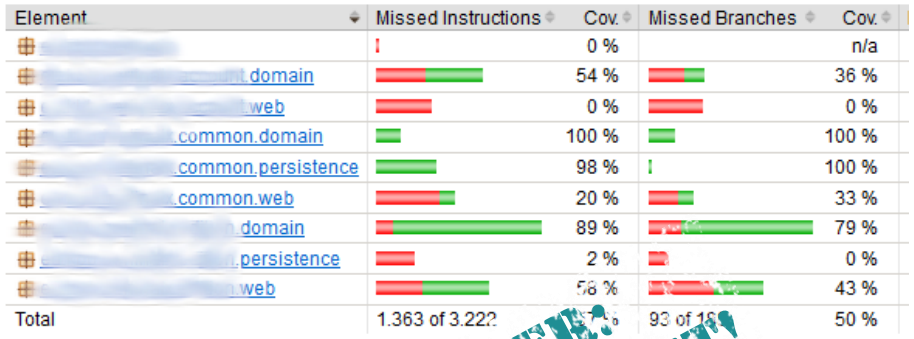

Element	Missed Instructions	Cov.	Missed Branches	Cov.
[redacted]		0 %		n/a
[redacted] domain		54 %		36 %
[redacted] web		0 %		0 %
[redacted] common.domain		100 %		100 %
[redacted] common.persistence		98 %		100 %
[redacted] common.web		20 %		33 %
[redacted] domain		89 %		79 %
[redacted] persistence		2 %		0 %
[redacted] web		58 %		43 %
Total	1.363 of 3.222	[redacted]	93 of 18[redacted]	50 %

- **Mutationstests** zeigen Qualität der **ACT**s und **ASSERT**s
  - Sind meine Tests gut genug?
  - Aber die schnellsten sind es leider immer noch nicht…

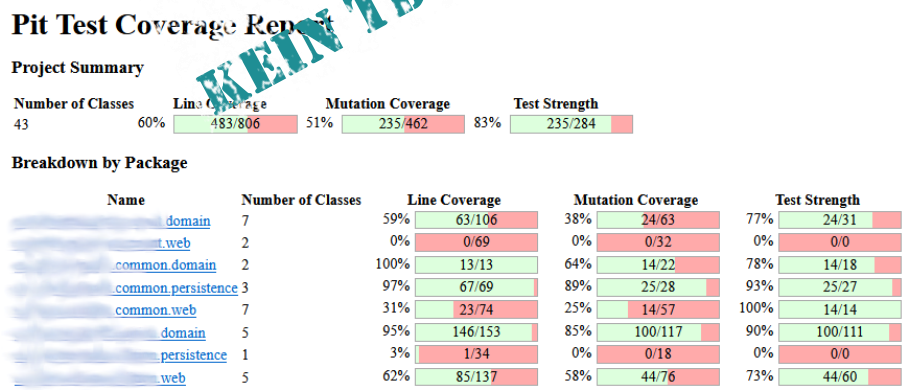

Pit Test Coverage Report

Project Summary

Number of Classes	Line Coverage		Mutation Coverage		Test Strength	
43	60%	483/806	51%	235/462	83%	235/284

Breakdown by Package

Name	Number of Classes	Line Coverage		Mutation Coverage		Test Strength	
[redacted] domain	7	59%	63/106	38%	24/63	77%	24/31
[redacted] t.web	2	0%	0/69	0%	0/32	0%	0/0
[redacted] common.domain	2	100%	13/13	64%	14/22	78%	14/18
[redacted] common.persistence	3	97%	67/69	89%	25/28	93%	25/27
[redacted] common.web	7	31%	23/74	25%	14/57	100%	14/14
[redacted] domain	5	95%	146/153	85%	100/117	90%	100/111
[redacted] persistence	1	3%	1/34	0%	0/18	0%	0/0
[redacted] web	5	62%	85/137	58%	44/76	73%	44/60

Was wir lernen mussten…

- JaCoCo vs. PIT
  - Test-driven development führt zu guter Code-Überdeckung, aber:
  - 100% Branch-Coverage bedeutet nicht zwangsläufig gute Tests

Element	Missed Instructions	Cov.	Missed Branches	Cov.
[redacted]		0 %		n/a
[redacted].domain		54 %		36 %
[redacted].web		0 %		0 %
[redacted].common.domain		100 %		100 %
[redacted].common.persistence		98 %		100 %
[redacted].common.web		20 %		33 %
[redacted].domain		89 %		79 %
[redacted].persistence		2 %		0 %
[redacted].web		58 %		43 %
Total	1.363 of 3.222	57 %	93 of 188	50 %

Pit Test Coverage Report

Project Summary

Number of Classes	Line Coverage		Mutation Coverage		Test Strength	
43	60%	483/806	51%	235/462	83%	235/284

Breakdown by Package

Name	Number of Classes	Line Coverage		Mutation Coverage		Test Strength	
[redacted].domain	7	59%	63/106	38%	24/63	77%	24/31
[redacted].t.web	2	0%	0/69	0%	0/32	0%	0/0
[redacted].common.domain	2	100%	13/13	64%	14/22	78%	14/18
[redacted].common.persistence	3	97%	67/69	89%	25/28	93%	25/27
[redacted].common.web	7	31%	23/74	25%	14/57	100%	14/14
[redacted].domain	5	95%	146/153	85%	100/117	90%	100/111
[redacted].persistence	1	3%	1/34	0%	0/18	0%	0/0
[redacted].web	5	62%	85/137	58%	44/76	73%	44/60

* Beispiel aus einem Non-TDD-Projekt

Und jetzt ein Beispiel aus einem TDD-Projekt

Pit Test Coverage Report

Project Summary

Number of Classes	Line Coverage		Mutation Coverage		Test Strength	
61	100%	1067/1067	91%	334/366	95%	334/353

Breakdown by Package

Name	Number of Classes	Line Coverage		Mutation Coverage		Test Strength	
[redacted]config	3	100%	9/9	67%	2/3	100%	2/2
[redacted]db.migration	5	100%	72/72	100%	28/28	100%	28/28
[redacted]domain.model	5	100%	150/150	94%	46/49	94%	46/49
[redacted]domain.model.value	21	100%	97/97	90%	44/49	90%	44/49
[redacted]domain.model.wrapper	1	100%	11/11	100%	9/9	100%	9/9
[redacted]domain.service	2	100%	125/125	95%	39/41	95%	39/41
[redacted]service	2	100%	144/144	100%	25/25	100%	25/25
[redacted]service.event	8	100%	48/48	97%	28/29	100%	28/28
[redacted]service.mapper	2	100%	101/101	100%	14/14	100%	14/14
[redacted]service.parser	3	100%	184/184	94%	66/70	96%	66/69
[redacted]service.parser.model	7	100%	94/94	69%	31/45	84%	31/37
[redacted]web.controller	2	100%	32/32	50%	2/4	100%	2/2

Ein genauer Blick lohnt sich auch hier

Was tun mit den Überlebenden?

Original Source-Code	Mutant	Analyseergebnis	Aktion
PASS	FAILED	Mutant gekillt	Gute Testqualität, keine Aktion
PASS	FAILED wegen eines Fehlers	Mutant invalide	Ignorieren, keine Aktion
PASS	PASS	Mutant hat überlebt	**Verbessere die Tests**
PASS	PASS	Mutant ist äquivalent	Als äquivalent markieren

Beispiel: wenn das UI leer bleiben kann…

- Kein Test zur Prüfung der angezeigten Werte aus den Enums

```
enum class BookingItemType(val value: String) {

    PRIVATE("privat"),
    BUSINESS("geschäftlich"),
    BUSINESS_ABROAD("geschäftlich (auswärtig)")

}
```

```
replaced return value with ""
```

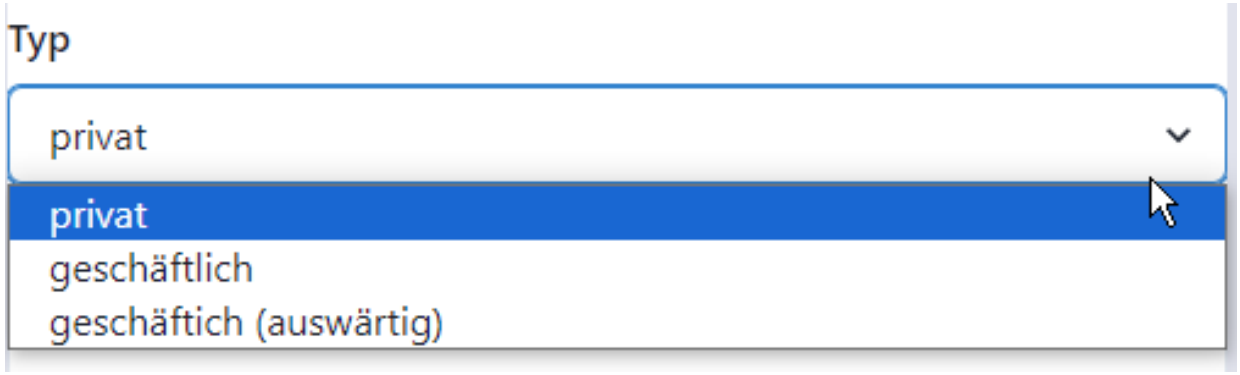

Beispiel: wenn nichts in der Datenbank landen kann

- Repository.save nicht aufgerufen – fehlendes verify

```
fun saveProject(projectValues: ProjectValues): Project {
    var project = repository.loadProject(project)
    project.updateWith(projectValues)

    project = repository.save(project)
    return project
}
```

```
removed call to …
```

Beispiel: wenn Code gar nicht erreichbar ist

- Überflüssiger Code – weil subsummiert

```
fun checkProject(project: Project) {
    checkProjectDates(project)
    checkProjectTimes(project)
}

fun checkProjectDates(project: Project) {
    require(project.date.start <= project.date.end) {
       "Der Starttag muss vor dem Endtag liegen oder gleich diesem sein."
    }
    checkProjectTimes(project)
}
```

```
removed call to …
```

Beispiel: wenn Grenzwertanalyse ein Fremdwort ist

- Grenzwerte nicht beachtet

```
class BookingItem(val start: LocalDate, val end: LocalDate) {

    fun checkDateInFuture() {
        require(start > LocalDate.now()) {
            "Der Start muss in der Zukunft liegen."
        }
    }

}
```

changed conditional boundary

Beispiel: wenn man manchmal eine Konstellation nicht herstellen kann

- Randomzahlenberechnung – ein Teil der Berechnung nie erreicht, warum nicht? Annahme falsch?

```
fun generateRandomValidPassword(length: Int): String {
    var password = ""
    do {
        password = generateRandomPassword(length)
    } while (!isValidPassword(password))
    return password
}

private fun isValidPassword(password: String): Boolean {
    // some implementation
}
```

```
replaced return value with true
```

Vorher vs. nachher ☺

Pit Test Coverage Report

Project Summary

Number of Classes	Line Coverage		Mutation Coverage		Test Strength	
61	100%	1067/1067	91%	334/366	95%	334/353

Breakdown by Package

Name	Number of Classes	Line Coverage		Mutation Coverage		Test Strength	
config	3	100%	9/9	67%	2/3	100%	2/2
db.migration	5	100%	72/72	100%	28/28	100%	28/28
domain.model	5	100%	150/150	94%	46/49	94%	46/49
domain.model.value	21	100%	97/97	90%	44/49	90%	44/49
domain.model.wrapper	1	100%	11/11	100%	9/9	100%	9/9
domain.service	2	100%	125/125	95%	39/41	95%	39/41
service	2	100%	144/144	100%	25/25	100%	25/25
service.event	8	100%	48/48	97%	28/29	100%	28/28
service.mapper	2	100%	101/101	100%	14/14	100%	14/14
service.parser	3	100%	184/184	94%	66/70	96%	66/69
service.parser.model	7	100%	94/94	69%	31/45	84%	31/37
web.controller	2	100%	32/32	50%	2/4	100%	2/2

Pit Test Coverage Report

Project Summary

Number of Classes	Line Coverage		Mutation Coverage		Test Strength	
67	100%	1169/1169	96%	382/396	98%	382/389

Breakdown by Package

Name	Number of Classes	Line Coverage		Mutation Coverage		Test Strength	
config	3	100%	9/9	100%	3/3	100%	3/3
db.migration	5	100%	72/72	100%	28/28	100%	28/28
domain.model	6	100%	156/156	98%	50/51	98%	50/51
domain.model.value	22	100%	106/106	100%	50/50	100%	50/50
domain.model.wrapper	1	100%	11/11	100%	9/9	100%	9/9
domain.service	2	100%	134/134	100%	44/44	100%	44/44
service	2	100%	145/145	100%	25/25	100%	25/25
service.event	10	100%	60/60	100%	37/37	100%	37/37
service.mapper	2	100%	117/117	100%	15/15	100%	15/15
service.parser	4	100%	216/216	98%	78/80	99%	78/79
service.parser.model	8	100%	109/109	82%	41/50	89%	41/46
web.controller	2	100%	34/34	50%	2/4	100%	2/2

* Zahlen unterscheiden sich leicht, weil die Entwicklung ja nicht stillgestanden hat

Fallstricke

- Einbeziehen von Integrationstests
  - Brauchen im Gegensatz zu Unit-Tests sehr lange und bringen manchmal keinen Mehrwert
  - Müssen so implementiert werden, dass sie auch bei mehrfachem Lauf parallel ausgeführt werden können
- Reports
  - Mutation-Tests überhaupt ausführen und nicht in der Pipeline ignorieren
  - Richtig lesen, nicht nur auf die Zahlen starren
  - Problemstellen nicht ignorieren, sondern zeitnah beheben
- Im Backend oft leichter zu integrieren als im Frontend
  - Besonders bei Verwendung nicht so verbreiteter Technologien, bspw. NX-Workspace

Handlungsempfehlungen

- Machen ☺!
- Da es immer noch sehr rechenintensiv ist
  - Ein typischer Fall für einen Nightly- oder Weekly-Build
    - Aber: Regelmäßiger Termin zum Auswerten der erstellten Reports
  - Notfalls Integrationstests ausschließen
    - Beispiel: Nur bei Merge auf den Main-Branch werden alle Tests einbezogen
- Nicht nur für die Pipeline konfigurieren, sondern auch für lokale Entwicklung

FRAGEN !?

Links

- https://pitest.org/
- https://stryker-mutator.io/
- https://www.jacoco.org/