

Juichi Takahashi, Ph. D
CTSO of Digital Hearts

もうちょっと楽に単体テストしませんか？

Books



Who am I?

Microsoft US



SAP Tokyo Lab



Sony Co.



Digital Hearts Co., CTSO

本日の主題

- Shift Left（単体テストで上流品質担保）しなければ、市場バグ流出はなくなる
- 正しく Shift Leftすれば、あなたの仕事は圧倒的に減る

幻想

バグ数/LOC = 品質



Agile品質担保に必要な4つのBox

(ウォーターフォールでもAgileでも開発サイクルは短くなっている)

i.e) 各イテレーション
でのアーキテクチャー
はどうする？

開発者の品質
フレームワーク

テスト担当者
の品質フレームワーク

i.e) Agile用のテスト計画書
(IEEE829)的なもの

i.e) リファクタリング
基準

開発者の具体的な
作業指針（上記フレームの
ブレイクダウン）

テスト担当者の具体的な
作業指針（上記フレームのブ
レイクダウン）

i.e) テストケースは書くの？
2wkで定量的な品質指標は？

寿一が勝手に想定する品質問題の本質

すべての日本の会社で

コードが汚い

コードを書くスキルが十分ではない
コードを指導するマネジメントが少ない
単体テスト書くスキルがない

機能追加でリファクタリングしない
から（短く・きれいに）

リファクタリングするスキルがない（Agile開発にとっては致命的）
リファクタリングに対するマネジメントの知識がない
リファクタリングしないので、単体テストができない（複雑度があがる）

ファイルが長くなる
複雑度が高くなる



バグが多発する原因のTop1, 2（論文で証明済）

アジャイルではこの悪いサイクルが加速する？


ウォーターフォール開発より時間と費用のかかるアジャイル？

Googleでは

良い自動化




悪い自動化



私がxxx時代の ソフトウェア品質の課題

- コードが汚く、単体テストができない（やる気がおきない）。統括もエンジニアも見て見ぬ振り
- コードが汚く、そして長いので単体テスト（コンポーネントレベルの品質担保）が戦略的にできないので、システムとして品質保証できない




リファクタリング！リファクタリング！
自動単体テスト！自動単体テスト！


今日話す品質の定義

- バグはすべて取ることができない
- 有限な時間の中で最適品質を探す、最適品質とは
 - **膨大なシステムテストは無意味。上流で効率的なテストを行う**
 - 品質はビジネス。早いタイミングでユーザの求めるソフトウェアを出すことが重要。要求仕様が変更され、コードが数十行変更されても、その日にリリースできる仕組みが必要
 - 最大公約数的なユーザ操作において、致命的なバグを起こさない (Operational Profile)
 - バグったとしても、ソフトウェア全体がいきなり死なない (ウォッチドッグ・Netflix的アプローチ)

品質にかかる費用はここ30年変わってない




大きなバグの海





大きなバグを見逃さない
限られた時間内で多くの仕事
をする

- **NG:** 組み合わせテスト（組み合わせのバグはほとんど出ない）
- **NG:** UIをなぞるだけの自動化テスト（遅すぎる）
- **OK:** 単体テストでの境界値テスト（網羅率を計測でき品質指標になる）
- **OK:** 単体テストの自動化


Shift Leftとは？




Caper Jonesの言うカオス




レイリー曲線




リスクがある




リスクがない



Cont.



上流テストを十分行いバグを検出したグループと 上流で十分バグを検出できなかったグループの比較



Dailyで上流品質を担保するための3つのこと


- 単体テスト
- リファクタリング
- 要求仕様のテストケース展開

Dailyで品質を担保するための3つのこと

- 単体テスト
- リファクタリング
- 要求仕様のテストケース展開


2017年Googleの網羅率データ

中央値は78%



Google単体テスト基準

- 網羅率60%：許容範囲（acceptable）
- 網羅率75%：推奨（Commendable）
- 網羅率90%：模範的(exemplary)



どの組織もこれから
初めましょう！

Google単体テスト基準

- 低いコード網羅は大きいエリアがテストされていない(low code coverage number does guarantee that large areas of the product are going completely untested)
- 高いコード網羅だからって品質が高いわけじゃない。もし高品質を確認したい場合はmutation testを使うのも手です (A high code coverage percentage does not guarantee high quality in the test coverage.)
- よく変更されるコードは網羅されるべき (Make sure that frequently changing code is covered)
- レガシーコードの網羅率をほっとくのはいいけど、でも少しずつ網羅率をあげていきましょう。you can adopt the ‘boy-scout rule’ (leave the campground cleaner than you found it)

75% Code Coverage

大変ですよね？

Assert突っ込むだけじゃ達成しませんよね？

つらい単体テストは

2 : 8 の法則を使いませんか？

あとテスト手法使うと網羅率あがりまっせ！

2割の部分に8割以上のバグが潜んでいます。

どこにバグが潜んでいるか？

Top 1: よく変更されるファイル


Top 2: 長いファイル

Top 3: 複雑度が高い

基本はファイル単位、関数単位ではない。ファイル単位で単体テスト計画を立てる必要がある。



↓ 20%を抽出



0
%



テスト・レビュー

2割の部分に8割以上のバグが潜んでいます。

どこにバグが潜んでいるか？

Top 1: よく変更されるファイル

Top 2: 長いファイル

Top 3: 複雑度が高い

基本はファイル単位、関数単位ではない

HotSpot概念

BugCache

Predicting Defects



Sung Kim • MIT

Tom Zimmermann • Saarland University

Jim Whitehead • UC Santa Cruz

Andreas Zeller • Saarland University

Function Level Optimal Hit Rates

Project	Function	Hit rate	Block	Pre-fetch	Replace
Apache 1.3	2,113	62%	15%	17%	BUG
Columba	8,428	68%	57%	20%	BUG
Eclipse	33,214	72%	20%	4%	BUG
JEdit	5,489	49%	85%	8%	BUG
Mozilla	8,203	55%	41%	14%	LRU
PostgreSQL	8,659	59%	29%	17%	LRU
Subversion	3,693	46%	71%	14%	BUG

Cache size = 10% of all functions/methods

The Problem

Which files should
we focus on?



Related Work

Khoshgoftaar et al.

Khoshgoftaar et al.

Ostrand et al.

Hassan et al.


*In previous work,
10% predicts 44%~78%
20% predicts 71~93%*

10% BugCache predicts 73~95%


BugCache. Top 10%



SKIP




Hot Spot値 高




Hot Spot値 低

Quality Measurement Criteria



出荷後のバグはどこから出るか？



2割の部分に8割以上のバグが潜んでいます。

どこにバグが潜んでいるか？

Top 1: よく変更されるファイル

Top 2: 長いファイル

Top 3: 複雑度が高い


基本はファイル単位、関数単位ではない

乱暴にファイルをぶった切る！

Weighted Methods Per Class(WMC)

$$WMC = \sum_{i=1}^n C_i$$

Martin Fowlerのクラス抽出



2割の部分に8割以上のバグが潜んでいます。

どこにバグが潜んでいるか？


Top 1: よく変更されるファイル

Top 2: 長いファイル

Top 3: 複雑度が高い

基本はファイル単位、関数単位ではない

FPあたりの
労働時間



複雑なコードのバグ修正成功確率

循環的複雑度	複雑さの状態	バグ混入確率
10以下	非常に良い構造	25%
30以上	構造的なリスクあり	40%
50以上	テスト不可能	70%
75以上	いかなる変更も誤修正を生む	98%

複雑な関数の修正怖いので、リファクタリングしたくない。。。でもどっちにしろ致命的なバグはでるので早めのリファクタリング
ちゃんと単体テスト書いてから、リファクタリングしましょう！

Dailyで上流品質を担保するための3つのこと

- 単体テスト
- リファクタリング
- 要求仕様のテストケース展開

要求仕様

- 要求仕様は品質を担保する上で重要なドキュメントです
(大きいバグになる)
- 要求仕様とテストケースは明示的にリンクを貼りましょう

要件定義を明確に行ったグループと行わなかったグループの不具合比較

発生不具合密度
(件/KFP)

10

5

0


不具合が2.7倍出る

2.25

6.45

要件が明確

要件が不明確




品質保証の実際 1

心構え編

品質保証とは

- 2つ以上の品質保証手法によって、リスクのあるコンポーネントをテストする
- リスクなければ、テストしなくていい（かな？）。
- リスクのあるコンポーネントとは。Hotspotが高い、新規追加、セキュリティ等々



リーダーが認識し、リスクヘッジする

テストができない箇所は特定しておく

- Race Condition(データベース・スレッドセーフ)
プログラミング言語やシステムの違いによるrace conditionバグを理解し、race conditionのバグを出さない工夫することはmustです。
- Memory Leak
- Security
- その他

テストできない箇所はレビューの重みをつけておく


品質保証の実際 2


Daily 品質の担保

テストは基本すべて自動化

すべての自動テストは最低その日に終了



現代では：その日に品質担保できないものは、出荷後確実に市場問題となる、市場問題って複雑なパフォーマンスやセキュリティテストの問題ではないですよね？






毎日定量的品質のわからないCI/CDって意味ありますか？

良い自動化





悪い自動化



あなたの自動化大丈夫ですか？

自動化健全性チェックリスト

- 網羅率あがってます？
- スピード十分ありますか？
- 自動化ですべてのバグは見つからないことを認識しています？UIなぞる自動化がすべてだと思ってませんか？



あなタテストは耐えられます？

システムテストでUIをただなぞってる自動化してませんか？

- 境界値バグ

自動単体テスト

- 状態遷移バグ

自動APIテスト

- Race Conditionバグ

レビュー

- セキュリティバグ


レビュー

- 非機能バグ

要求仕様段階でverification pointを明記


あれ？組み合わせテストは？

テストケースの重み基準




テストスピード

単体テストがお得



システムテスト（自動化）
60分




統合テスト
10分




単体テスト
3分

テストスピード



MVC分離でUIテストの最小化・テスト時間の最小化



Viewテストを分離する2つの理由



技術的な理由

- Viewのテストは時間がかかり、UIの変更は頻繁に起こる
- Viewテスト単体テスト化が困難で、コストのかかるシステムテストになるため
- コード上でviewとコントロールを分離する(例: javascriptに計算を持たせない)

不条理な理由

- いくら事前に説明しても、企画と上司はものができてからUI変更を命令する
- 企画と上司は出荷直前でもUI変更はできると信じ、それを命令する

事例) Testing Strategies




60 min(10 times a day)

**Running 400
System Test Cases**

You Write code,
You Test code by JUnit as **100% Coverage**
(only you changed one, not for legacy code)

事例) テストスピード



本日の主題

- Shift Left（上流品質担保）しなければ、市場バグ流出は
なくなる
- 正しく Shift Leftすれば、あなたの仕事は圧倒的に減る


Next Step : まずはアクションを 起こしてみませんか？

- 新規に書く関数だけでも、単体テスト書いてCI/CDフレームワークに入れませんか？Commitごとのビルド&API test
- 品質分析はどうでしょうか？なぜ後半にたくさんのバグを見つかってるか分析してみませんか？分析コストはかかりますが、総バグ数は半減すると思いますが。

Appendix

Testing Scale at Google

- 4.2 million individual tests running continuously
 - Testing runs before and after code submission
- 150 million test executions / day (averaging 35 runs / test / day)
- Distributed using internal version of [bazel.io](#) to a large compute farm
- Almost all testing is automated - no time for Quality Assurance
- 13,000+ individual project teams - all submitting to one [branch](#)
- Drives continuous delivery for Google
- 99% of all test executions pass




Google

Testing at Google

Test & Build System Fast Facts

- Recall, Google's emphasis on speed – 20+ code changes occur per minute
 - Code churn - **50%** of code changes every month
- 65k builds/day
- 20M builds/year



Source:
<http://googletesting.blogspot.com/2010/04/googles-innovation-factory-and-how.html>

Testing at Google

Test & Build System Fast Facts

- 120k test suites in code base
- 7.5M test suites run/day
- 120M individual tests run/day
- Every affect test run after each code change
- Tests run on all major OS/browser pairs


Quality Cost Deliver

2000年でQCDの研究開発はすでに終わっている

QCD +

QCDはとっとと終わらせて+にいきませんか？
でも今日は+の話ではなくQCDをとっとと終わらせる話

多くのIT経営者の考え (やめちゃったけどOさんもそう言っていた)



多くの会社

