

Call for Members for AY2022

小林研の研究内容の紹介

難しいこと面倒なことを
自動化することで
「ソフトウェア開発を
楽し~~た~~いたい人」
を募集します



小林研の研究領域

○ ソフトウェア工学

- ソフトウェア保守・進化支援 [2007~]
 - 「**既にある(難解な)ソフトウェアの変更・修正**」
 - プログラム理解支援, デバッグ技法, トレーサビリティ管理
- ソフトウェア開発支援環境 [2007~]
 - 「**面倒なこと・難しいことの自動化**」
 - プログラム解析ツール, デバッガ, DevOps, Infra. as Code
- ソフトウェア分析・設計技法 [1997~]
 - 「**コードより抽象度の高い表現とは?**」
 - 設計方法論, アーキテクチャ, デザインパターン

○ 過去のデータに基づく**帰納的アプローチ**

- リポジトリマイニング, 機械学習に基づく手法

小林研の大きな研究目標

- ソフトウェア開発における属人性の軽減
 - 「できる人」を増やす
 - 熟練者の知識・経験を可能な限り「形式知」へ

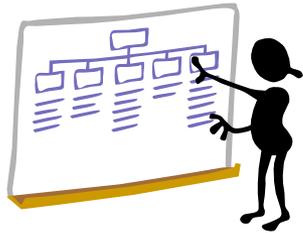


なぜ「知識や経験」に着目するのか？

- ソフトウェア開発は高度な知的創造活動
 - 実現している機能 ⇔ ソースコードの変換作業は現在でも説明困難な活動
 - 開発者の理解・行動プロセスの補助が必要
- 2方向の支援アプローチ
 - 演繹的：プログラムの意味を解析し補助
 - 部分的なプログラムの意味を用いて理解・解析を支援
 - 命令単位での意味 → 関数単位での意味 → …
 - 支援の確度は高いが、適用範囲が限定的になりがち
 - 帰納的：事例(プログラム・活動)を解析し補助
 - 多数の事例から意味/意図を導出：ML based AI的アプローチ
 - 適用範囲が広いが、支援の確度は事例数と共通性に依存

こちらを
採用

研究アプローチ (基本的な考え方)



モデルを定義



高コスト



モデルに基づき
暗黙知を記述
(形式知化)



(リポジトリに格納した)
形式知に基づくツール支援

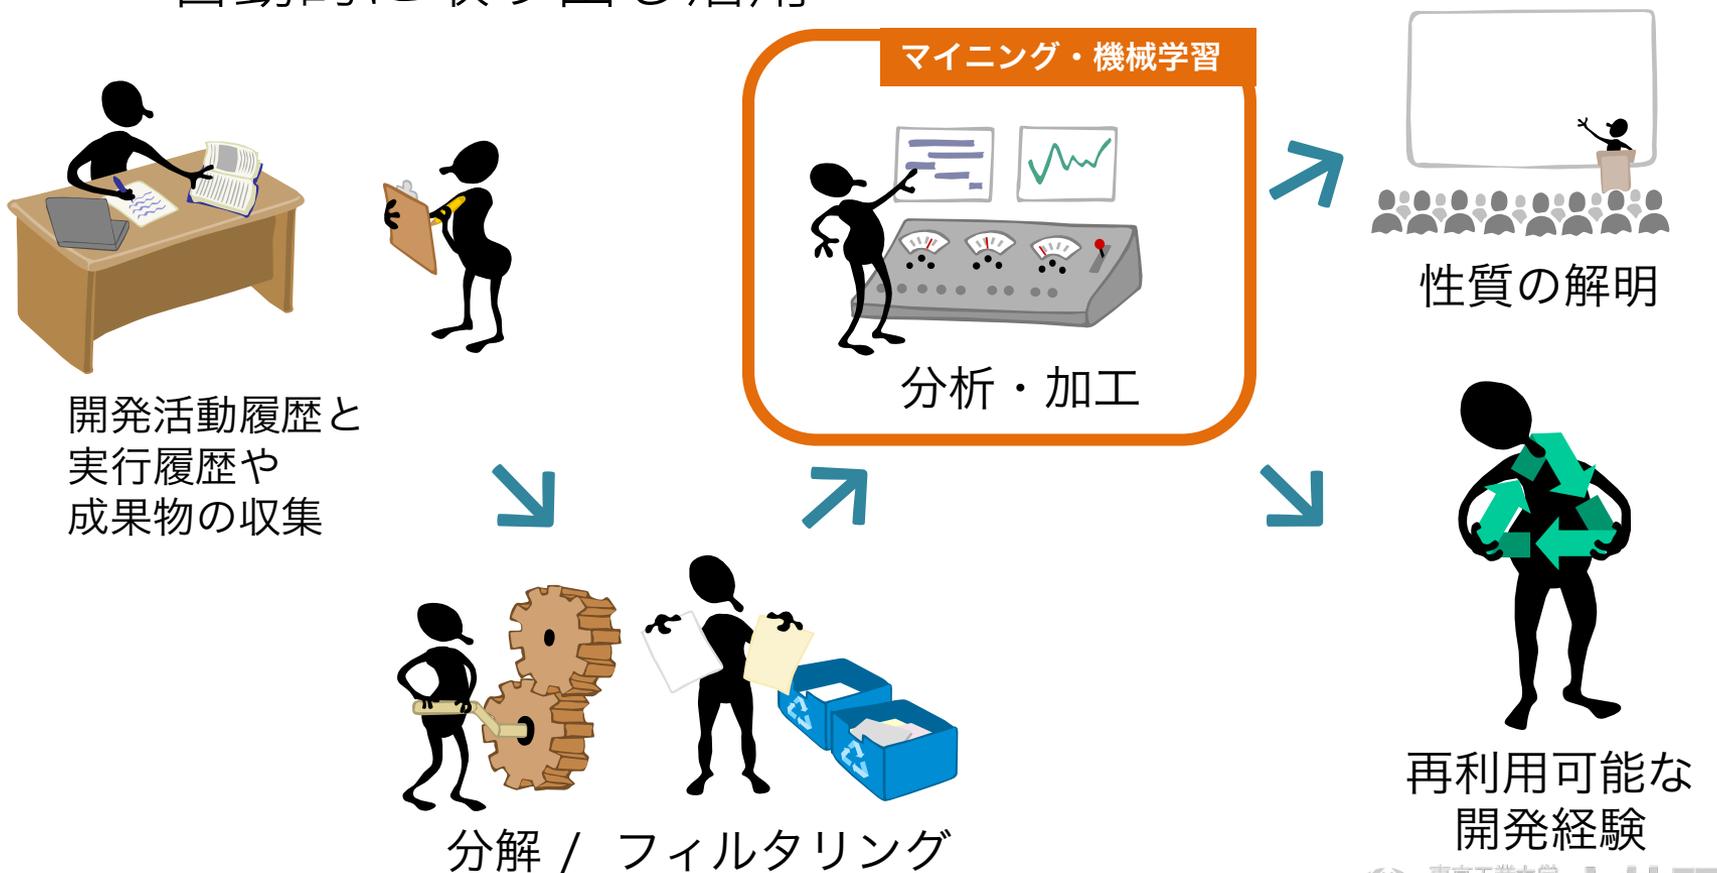
- 作業の自動化
- 作業結果の検証
- 作業内容の推薦

自動運転でいうと:
- 完全自動 (手放し)
- ハンドルアシスト
- ブレーキアシスト
- ナビゲーション

研究アプローチ (帰納的アプローチ)

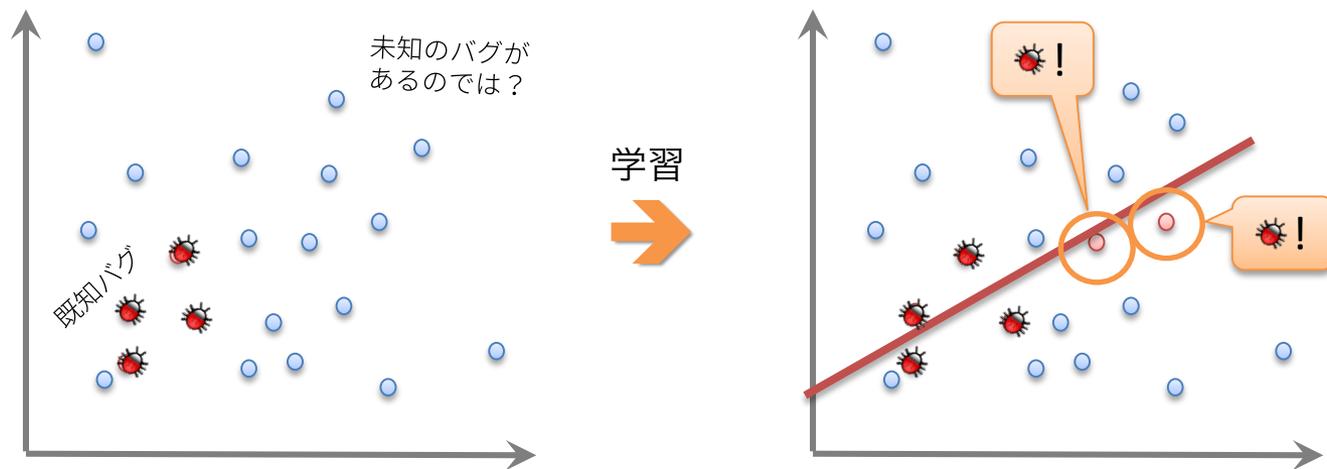
○ リポジトリマイニング・ML4SE

- 過去の成果物・履歴から再利用可能な経験を自動的に取り出し活用

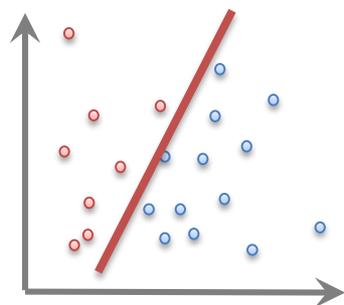


既存データからの経験抽出

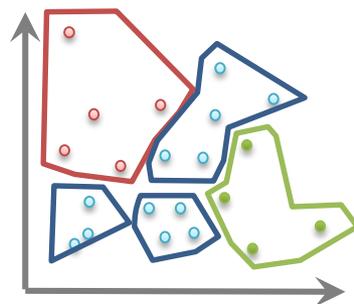
- マイニング・機械学習・統計処理を応用



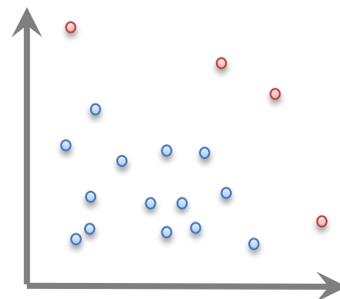
- 様々な技法を用いて経験を抽出



分類



クラスタリング



外れ値検出

小林研が特に力を入れている領域

- ソフトウェア保守・進化
 - 既存のソフトへの機能追加
 - 明示的・潜在的なバグを生み出さない変更を支援
 - 有益な情報のドキュメント化, 情報提示
 - 既存のソフトのデバッグ
 - バグの箇所を特定し, 取り除くための支援



BUG PROTECTION
バグ防止



変更漏れの発見
開発リポジトリをマイニングし変更漏れを検出



Just-in-Time 変更推薦
開発者の行動を分析し, 次に変更すべき箇所を推薦



FAULT LOCALIZATION
デバッグ支援



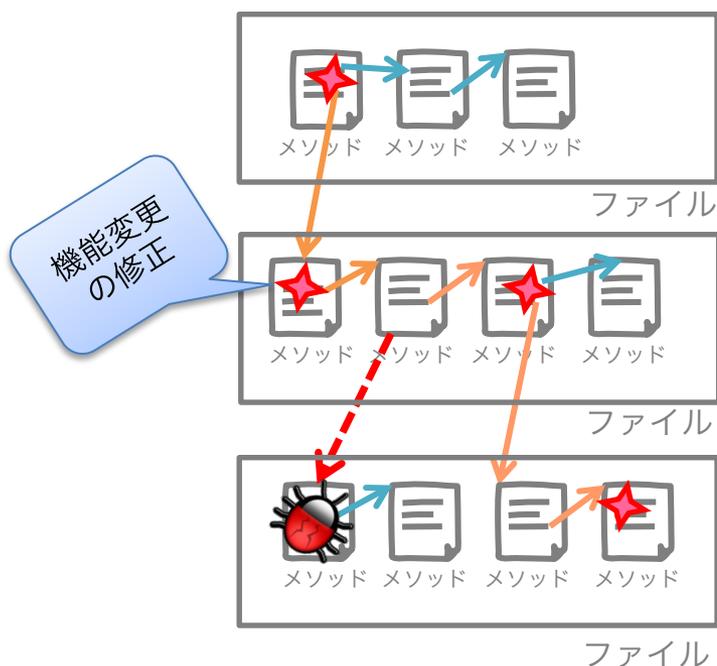
バグ箇所の自動特定
テスト実行の成否状況に基づいてバグの場所を推定



実行情報の抽象化・可視化
実行時のプログラム挙動を分かりやすく提示

バグが混入する1つの要因 = 変更漏れ

- プログラムは複雑な依存関係をもつ
 - 変更波及：変更は様々な場所に伝播する
 - 変更波及を扱う手法 = 波及解析 (Impact Analysis)



- 静的解析で波及先の特定は(ある程度)可能
 - コードが必須 = フレームワークなどを介すると分断される
 - ポインタ・動的束縛は「可能性」
- 全ての静的依存に波及するわけではない
 - 不要な関係が多いという報告

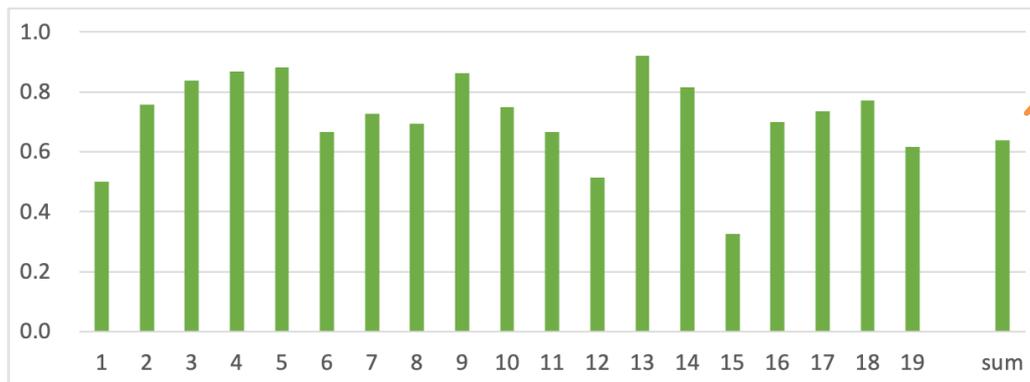
「変更漏れバグ」の現状分析 [修論2020]

- 実際に「変更漏れ」はどの程度・どんな規模で起こる？
 - 19のOSSから計2840件のバグ管理情報とリポジトリを調査
 - バグチケットから {Bug混入の編集, その修正} ペアを抽出

!! **平均 44.7%** のバグ原因に変更漏れが含まれる
!! 90.7%で5ファイル以下, **53.2%は1ファイル**

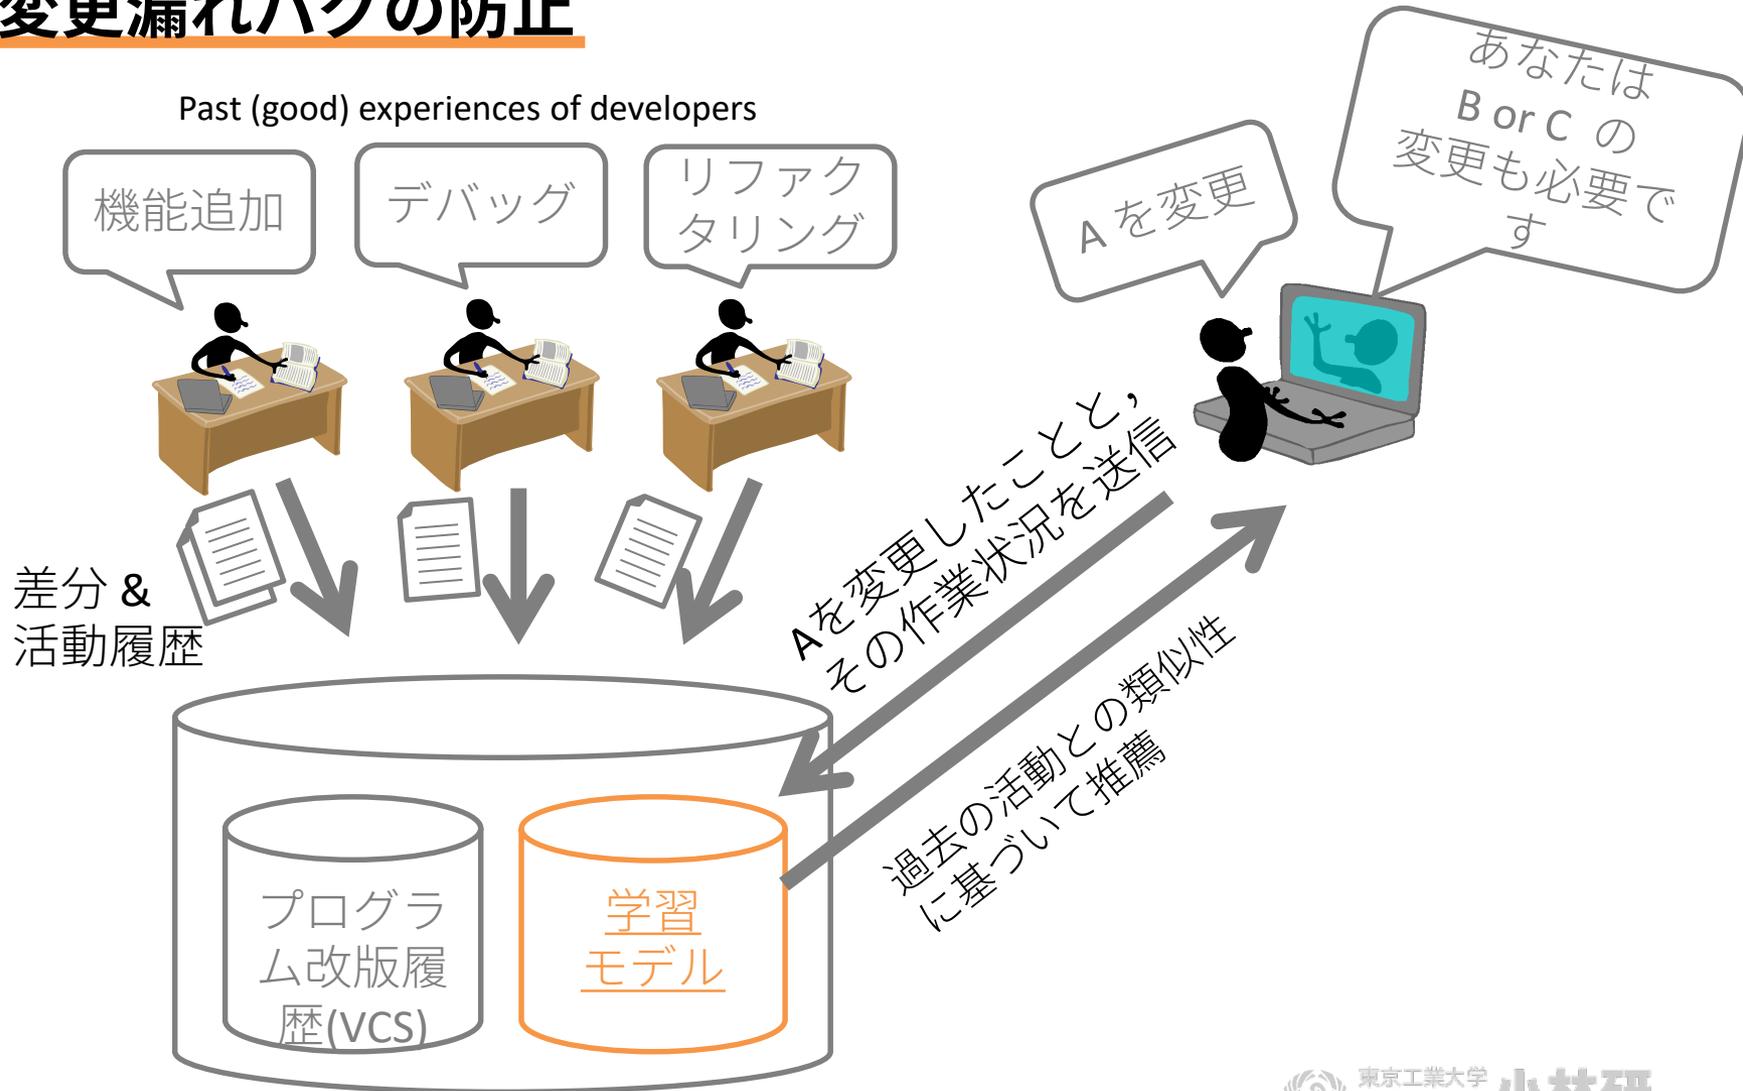
- 改版履歴の分析でどの程度発見できる？

63.9%



活動の分析による経験(マイクロプロセス)の再利用

変更漏れバグの防止



変更支援手法：ツールの出力例

Report for the commit 763a9fba93b91eb730e563eadb08de0444e80980

Changed files in the commit:

- java/org/apache/catalina/ha/session/LocalStrings.properties
- java/org/apache/catalina/core/LocalStrings.properties
- java/org/apache/tomcat/util/descriptor/web/LocalStrings.properties

[1] Top 1 candidate of overlooked change is :

- java/org/apache/jasper/resources/LocalStrings_ja.properties

because it was 66 % changed when the following your modified files were changed.

- java/org/apache/catalina/ha/session/LocalStrings.properties
- java/org/apache/catalina/core/LocalStrings.properties

It happened 2 times in past. For instances :

```
+-----+
|CommitID   : #4ead17
|AuthorDate : Thu Mar 30 18:06:46 JST 2017
|Author     : Mark Thomas<markt@apache.org>
|Message    : Replace the use of (...) to delimit values in messages with ...
+-----+
|CommitID   : #d46012
|AuthorDate : Thu Mar 30 06:34:18 JST 2017
|Author     : Mark Thomas<markt@apache.org>
|Message    : Fix https://bz.apache.org/bugzilla/show_bug.cgi?id=60932 Corr...
```

[2] 2nd candidate of overlooked change is :

- java/org/apache/jasper/resources/LocalStrings_fr.properties

...

開発者の
変更内容

変更忘れ
候補

理由

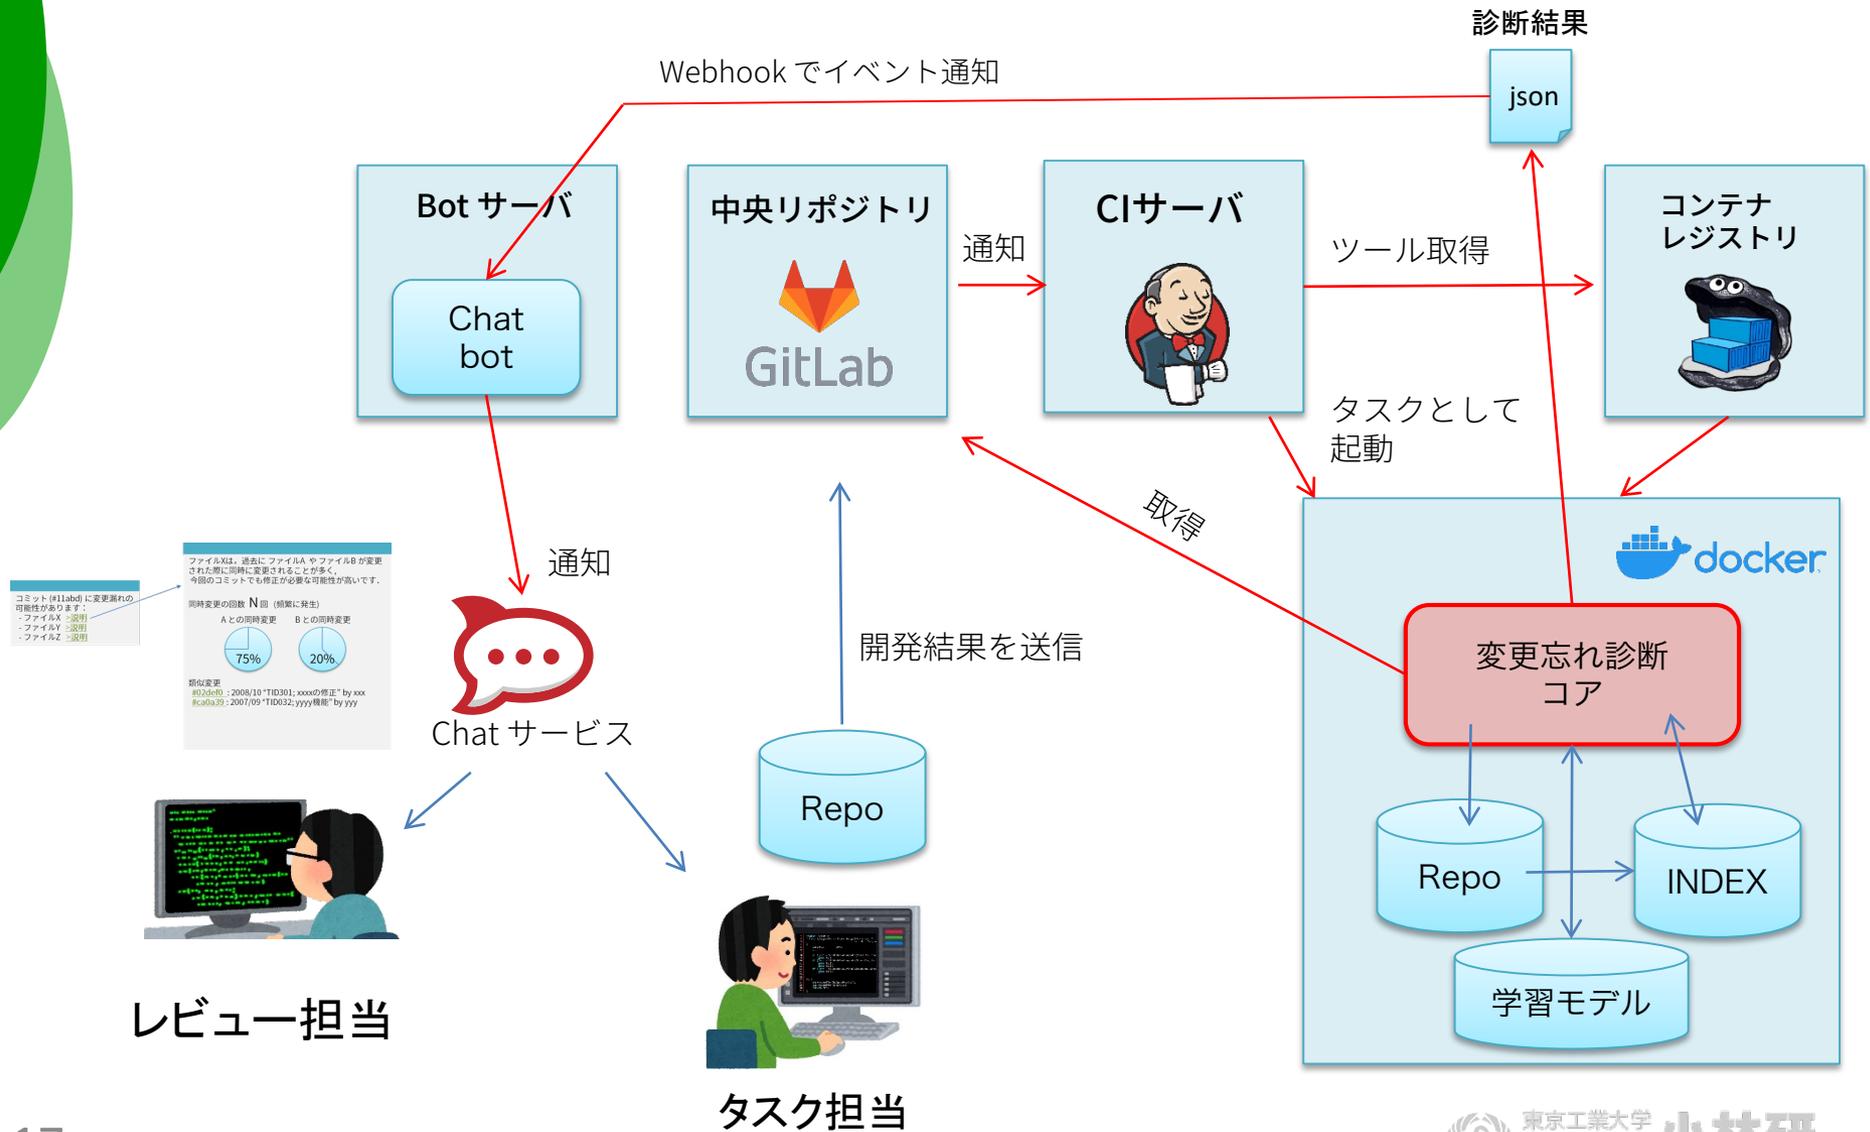
条件付き確率
66%

過去の
類似変更

変更支援手法：我々の研究成果

- 変更履歴の質と推薦精度の関係を分析 
 - 「古い履歴は使うべきではない」「分割コミットは悪影響」
 - EclipseやFirefox等の大規模OSSリポジトリで検証
 - 2017年度情報処理学会論文誌 論文賞受賞
- Configurable Software(CS) 向け拡張
 - 前処理の影響と変更箇所の間関係を考慮した推薦
- マイニング範囲の動的決定 
 - マイニングする履歴の量を推薦毎に動的に自動決定
 - 12のOSSで固定値より優れた精度を実現
- 機械学習を用いた変更忘れ指摘手法の開発
 - データマイニングではなく機械学習での解決方法を提案
 - 古典的ML, DNNを用いた複雑な関係性の推定

変更支援手法：ChatOps環境への組み込み (共同研究)



複合コミットの問題

- 複合コミット(CC)：複数の目的を含むコミット
 - a.k.a Tangled Commit, Multi-purpose change…
- 問題
 - 複数の変更が「絡まる」と分かりづらい
 - レビューや再利用が困難
 - コミット解析に基づく手法に悪影響 [5, 21]
 - 「大きな変更は除外」等の経験則で対応
 - 有効な共変更関係を見落とす可能性

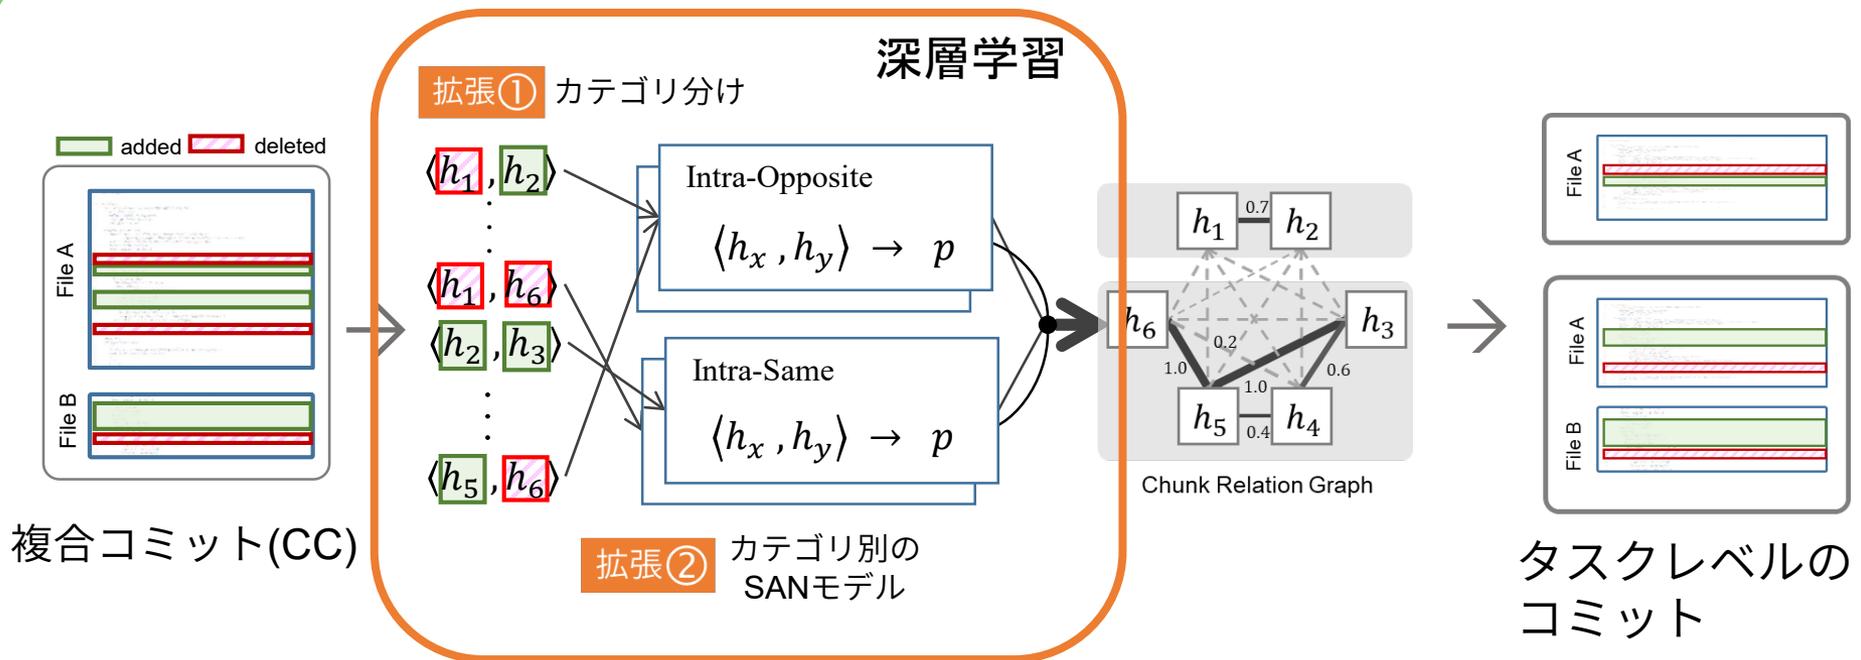


本研究の
きっかけ

- [5] H. A. Nguyen et al., “Filtering noise in mixed-purpose fixing commits to improve defect prediction and localization”, Proc. ISSRE, 2013
- [21] K. Herzig et al, “The impact of tangled code changes on defect prediction models”. Empirical Software Engineering 21(2), 2016

変更支援手法：精度改善にむけて

- コミットを適切な粒度に分解 ('19～)
 - 「連続する変更行」の単位で抽出
 - DNN (SAN, Tree-based CNN)による特徴学習
→ 従来手法より高精度にコミットを分割



変更支援手法：精度改善にむけて

○ コミット分割の応用：自動ステージング

○ CLIツールを開発

1) コミット忘れてた!
→ 起動

2) 分割案提示

3) チャンク単位で
自動分割案を調整

4) 連続コミット

CLIツール c-four スクリーンショット

The screenshot shows the c-four CLI tool interface. At the top, it displays 'Commit Number: 2 / 2'. The main area is split into two panes. The left pane shows a list of commit chunks with their IDs and counts, such as (49, 59), (53, 72), (74, 84), and (85, 85). Below this, it shows 'Related and Pending chunks(2 chunks)' with details like '(10, 17)Related(Page: 1)' and '(11, 20)Related(Page: 1)'. The right pane shows Python code for the tool, including a function to prompt for commit creation and logic for handling pending chunks. At the bottom, there is a 'Commit Message' field with the text 'fix confirm dialog' and a 'Prev Commit' field with the text 'make commits!'. Red annotations (1) through (5) are placed on the screenshot to highlight specific features: (1) points to the chunk list, (2) to the related chunks, (3) to the code pane, (4) to the commit message field, and (5) to the 'make commits!' button.



Available at
github.com/tklab-group/c-four

小林研が特に力を入れている領域 [再掲]

- ソフトウェア保守・進化
 - 既存のソフトへの機能追加
 - 明示的・潜在的なバグを生み出さない変更を支援
 - 既存のソフトのデバッグ
 - バグの箇所を特定し，取り除くための支援

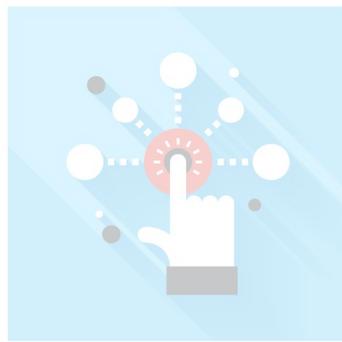


BUG PROTECTION
バグ防止



変更漏れの発見

開発リポジトリをマイニングし変更漏れを検出

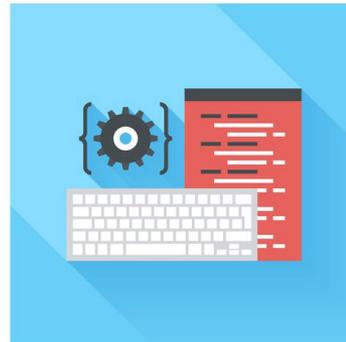


Just-in-Time 変更推薦

開発者の行動を分析し，次に変更すべき箇所を推薦



FAULT LOCALIZATION
デバッグ支援



バグ箇所の自動特定

テスト実行の成否状況に基づいてバグの場所を推定



実行情報の抽象化・可視化

実行時のプログラム挙動を分かりやすく提示

デバッグ支援の取り組み

○ バグ発見・個所特定

- 深層学習によるバグ含有予測 (2019~)
- 動的解析を用いたバグ箇所特定 (2011~) 
- 大規模実行トレース解析による異常検知 (2019) 

○ 新しいデバッグ環境の開発

- 仮想ファイルシステムを用いたデバッグ環境 (2017~) 
- Jupyterを用いたデバッグ環境 (2020)

○ 振る舞い・機能に特化したプログラム理解支援

- 実行履歴の抽象化・可視化(2009~) 
- 機能実現個所の特定 (2012~)
- プログラム要約 (2017~)

バグ箇所の自動特定

○ Spectrum-based Debugging

- 成功実行と失敗実行の差分から、失敗の原因となった「バグ原因箇所」を推定
 - コード解析・理解なしに推定可能
- 詳細な実行トレースの分析による新しい手法を考案 

(x,y,z) = (3,3,5) の時はPass(成功)

(x,y,z) = (2,1,3) の時はFail(失敗)

成功実行で通ることが少なく、失敗実行で通ることが多い

成功実行で通ることが多く、失敗実行で通ることが少ない

	Test Cases					
	3,3,5	1,2,3	3,2,1	5,5,5	5,3,4	2,1,3
1: read("Enter 3 numbers:", x, y, z);	•	•	•	•	•	•
2: m = z;	•	•	•	•	•	•
3: if (y<z)	•	•	•	•	•	•
4: if (x<y)		•				
5: m = y;		•				
6: else if (x<z)	•				•	
7: m = y;	•					•
8: else	•					
9: if (x>y)			•			
10: m = y;			•			
11: else if (x>z)				•		
12: m = x;						
13: print("Middle number is:", m);	•	•	•	•	•	•
	Pass Status: P P P P P F					

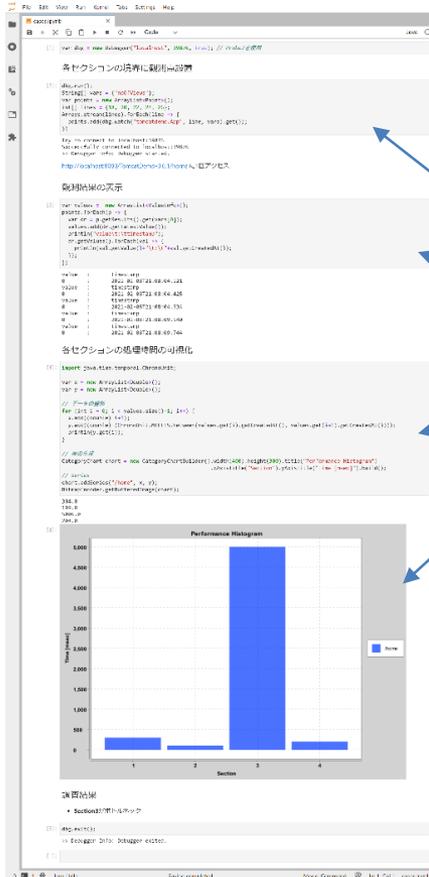
どの行が実行されたか

[Jones+2002] Jones et al. "Visualization of test information to assist fault localization" in Proc. ICSE2002

図は <http://pleuma.cc.gatech.edu/aristotle/Tools/tarantula/vizworkshop.ppt> Slide p12 より. 引用

デバッグ支援：新しいデバッグ環境 文芸的デバッグ環境

○ 新しいデバッグ支援環境 JISDLab を開発



- 観測の影響を最小限に
 - 実行を停止せずに観測
 - 実行中に「観測したい値」を変更可能
- Scriptable Debugging + Literate Program
 - デバッグ作業をスクリプト記述
 - 観測結果の加工・保存も可能
- “実行できるバグレポート”の実現
 - 不具合の再現・状況確認・解析を可能に

Webブラウザから
Web App @Tomcat をデバッグ

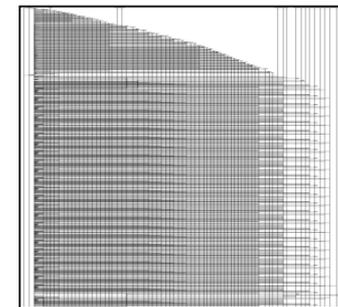


Available at
github.com/tklab-group/JISDLab

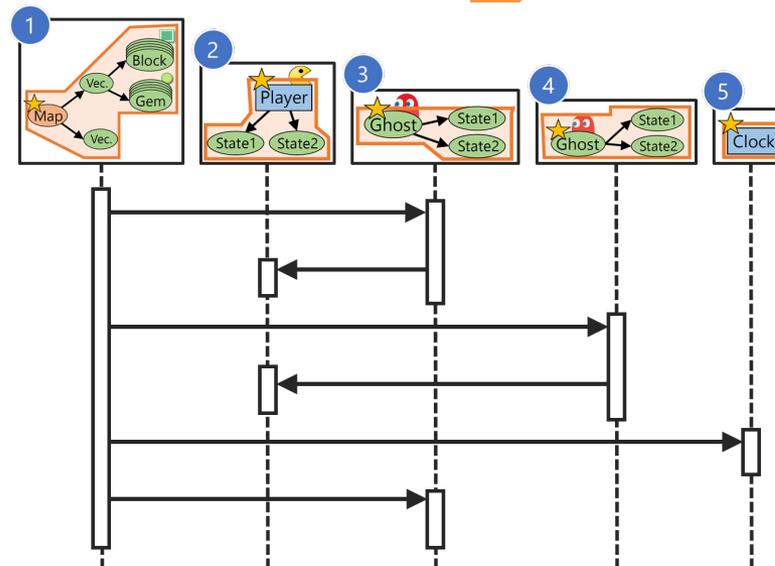
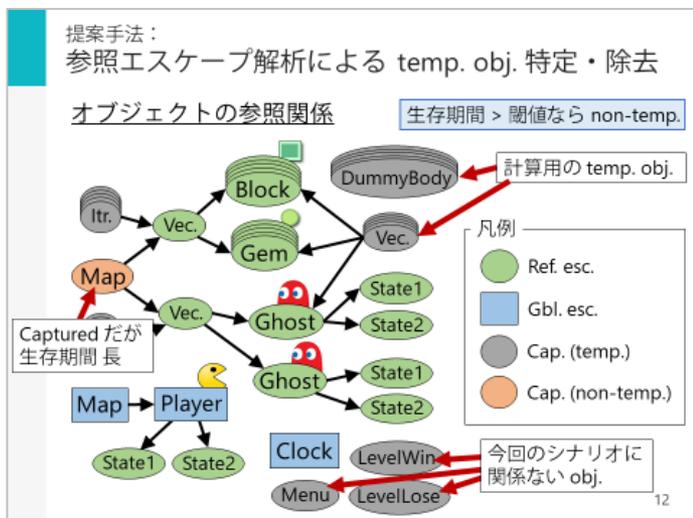
実行履歴のシーケンス図による可視化

○ 実行履歴の抽象化・可視化

- 一般的なソフトウェアの実行 = 可視化困難
- プログラムを解析しオブジェクトをグループ化
- 全体像が把握しやすい「実行概要」を提供



生成したシーケンス図



21

提案手法で生成する実行概要シーケンス図

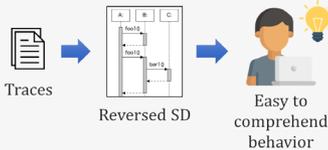
デバッグ支援：プログラム振る舞い理解支援 シーケンス図の活用

○ SDExplore: 大規模SD表示ツールキット

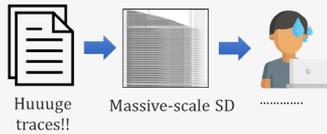
- Won Best Tool Demo Award @ IEEE/ACM ICPC 2018

Program Comprehension with Reversed SD

Ideal



Real



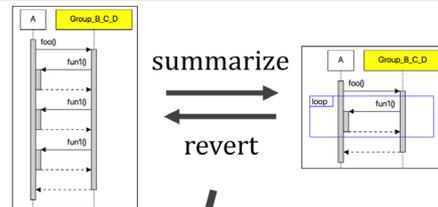
Existing tools...

- Sometimes **Crash**
- **Hard to re-use**
- ... etc.

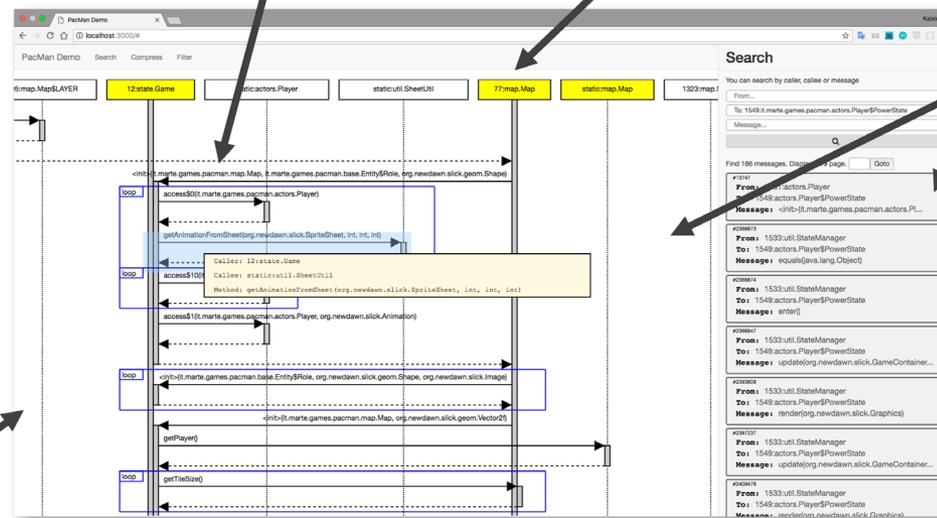
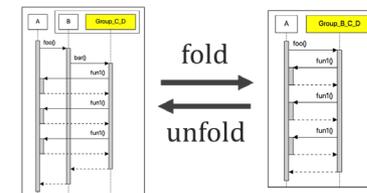
Browser-based tool

- Easy to use
- Platform-free
- Embed to Web page

Interactive Loop Summarization



Interactive group folding/unfolding



Rich features for exploration

- Searching
- Filtering
- Zooming
- ... etc.

Operation Logging

Records interactions to support user activities analysis.

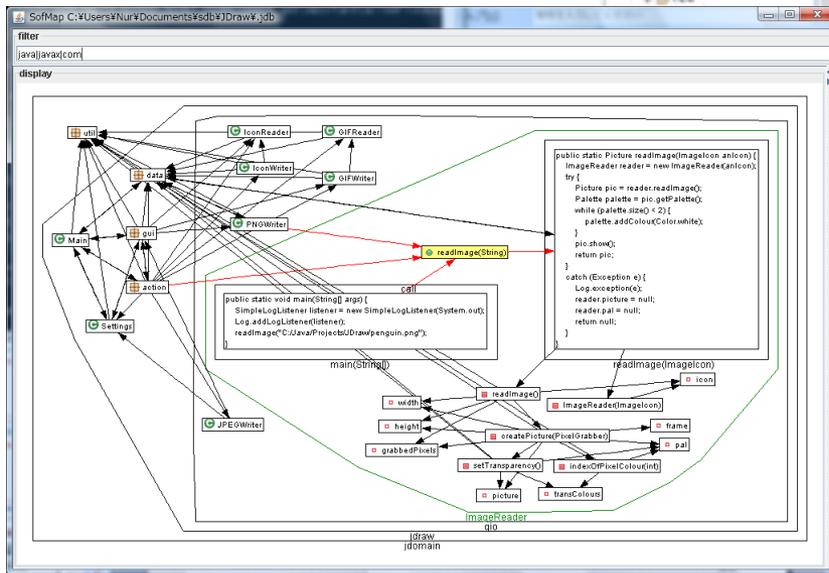
Smooth exploration for massive-scale SD

< 1 sec responses time for SD with **3K** objs, **2.5M** msgs

そのほかの取り組み：静的解析ツール

○ コードの静的解析・可視化

多粒度表示による
ナビゲーション
Sofmap



違反検出箇所を
グラフィカルに表示

柔軟なオリジナルルール
定義機能

XPathで
簡単にルール作成

C言語向けコーディングチェッカー
CX-Checker
大手自動車部品メーカー・他数社で導入検討中
情報処理学会山下研究賞受賞

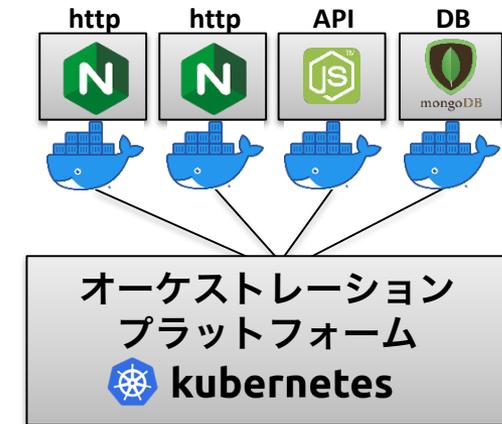
これまでの取り組み：IaCの可視化

- VM・コンテナによる環境(インフラ)構築
 - 例：レンタルサーバ, Amazon AWS, Dockerの利用
 - 手作業による間違い防止・効率化が必要
 - IaCスクリプト記述による自動化が主流に
- IaCスクリプトも「コード」
 - 多量のIaCスクリプト = やはり理解しづらい
 - ソースコードと同様にソフトウェア工学が必要
- SE 4 IaC
 - 設計支援：記述支援, 推薦・警告, 性能見積もり
 - 保守支援：理解支援, バグ発見, リファクタリング
 - ...

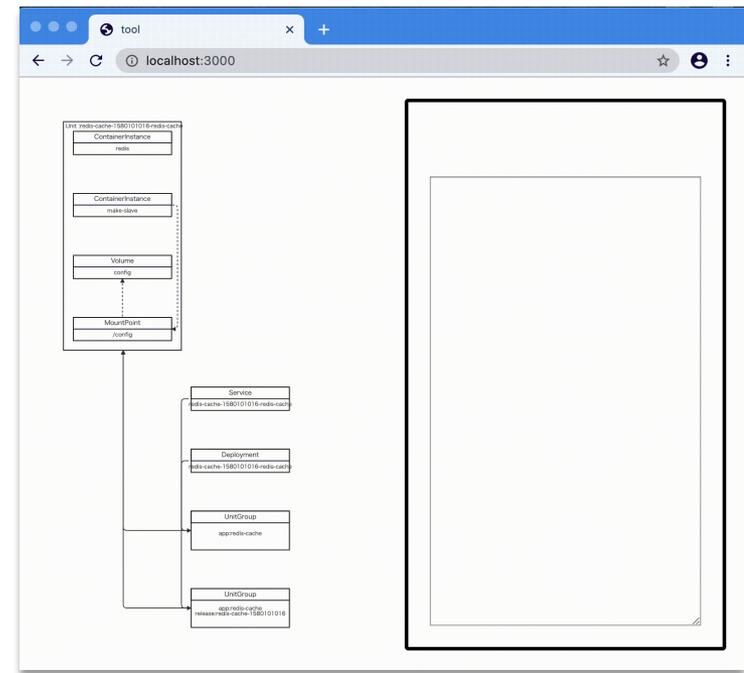
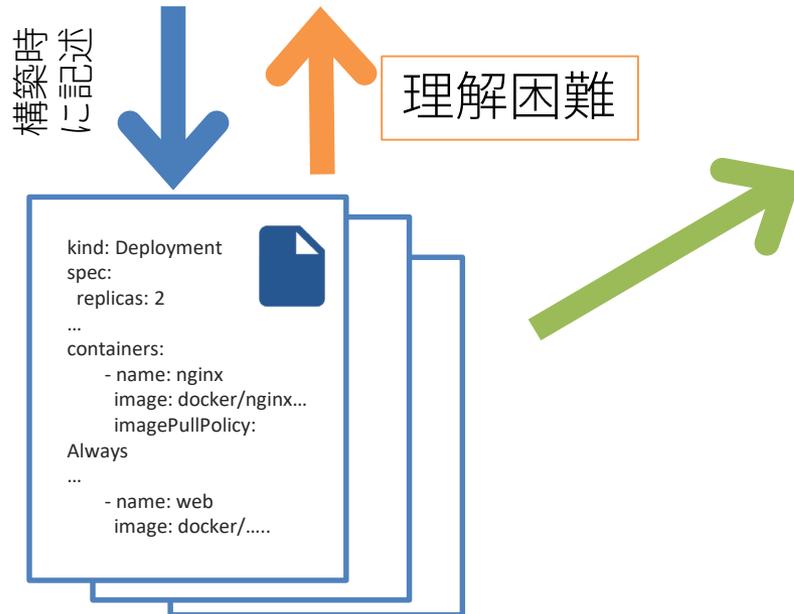
19年度 卒論

21年度 卒論

これまでの取り組み：IaCの可視化



- ソースコードと同様にリバースエンジニアリング手法を適用
- 実際のサービス設定ファイルに適用



Kubernetes用可視化ツール (19年度 卒論)

2022年度メンバー

○ 学生は11名前後

- 教員：小林
- D：1名
 - 静的解析(APIパターン)
- M2：4名
 - 行動解析(変更推薦) x 2, 静的解析(コミット分割), デバッグ環境
- M1：3名
 - 行動解析(変更推薦), IaC, 未定
- 学部：3名
 - 行動解析(変更推薦), 未定 x 2

修士は 3~4名/学年
他大学からの
入学も多数実績あり

○ 連携研究室・大学・企業

- 林研@大岡山とはいろいろ連携
- 大学：京大, 奈良先端大, スイス Lugano大, 濠 Adelaide大
- 企業：IT/SI企業 3社 (4件)

必要な知識・関連講義など

- 必須知識ではありませんが以下は関連します
 - 手続き型・オブジェクトプログラミング言語
 - 数理論理学，オートマトン，コンパイラ
 - データベース，情報検索，データマイニング，機械学習
- ソフトウェア開発・プログラミングで困ったことがある人はすごく向いています
 - その内容が研究のきっかけです
 - 開発環境に不満 → 支援ツールは良くある話です
 - 開発者を楽に・幸せにすること = SEのゴールの1つ
- 開発スキルを得たい人も向いています
 - その動機に関連する書籍・事例はたくさん提供できます

最近の言語事情@小林研

実装言語：Java / python / Go
解析対象：Javaが多い

C/C++/C# も扱う。珍しいところだと
COBOL, Simulink, (Docker, Kubernetes)

ソフトウェア工学でプログラミングをもっと楽しく



東京工業大学
情報理工学院 **小林研**
Software Analytics Laboratory

2022年から **すずかけ台キャンパスに移転** しました

最寄り駅：東急 田園都市線 すずかけ台 駅

問合わせ先：

小林隆志 <tkobaya@c.titech.ac.jp>

研究室Webページで過去の修士論文や
外部発表論文も参照してみてください

<http://www.sa.cs.titech.ac.jp/>