本資料公開場所

Call for Members for AY2025

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に したい人」
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)

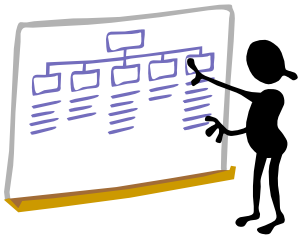

モデルを定義

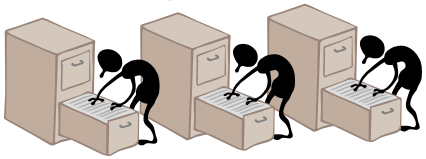

高コスト

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

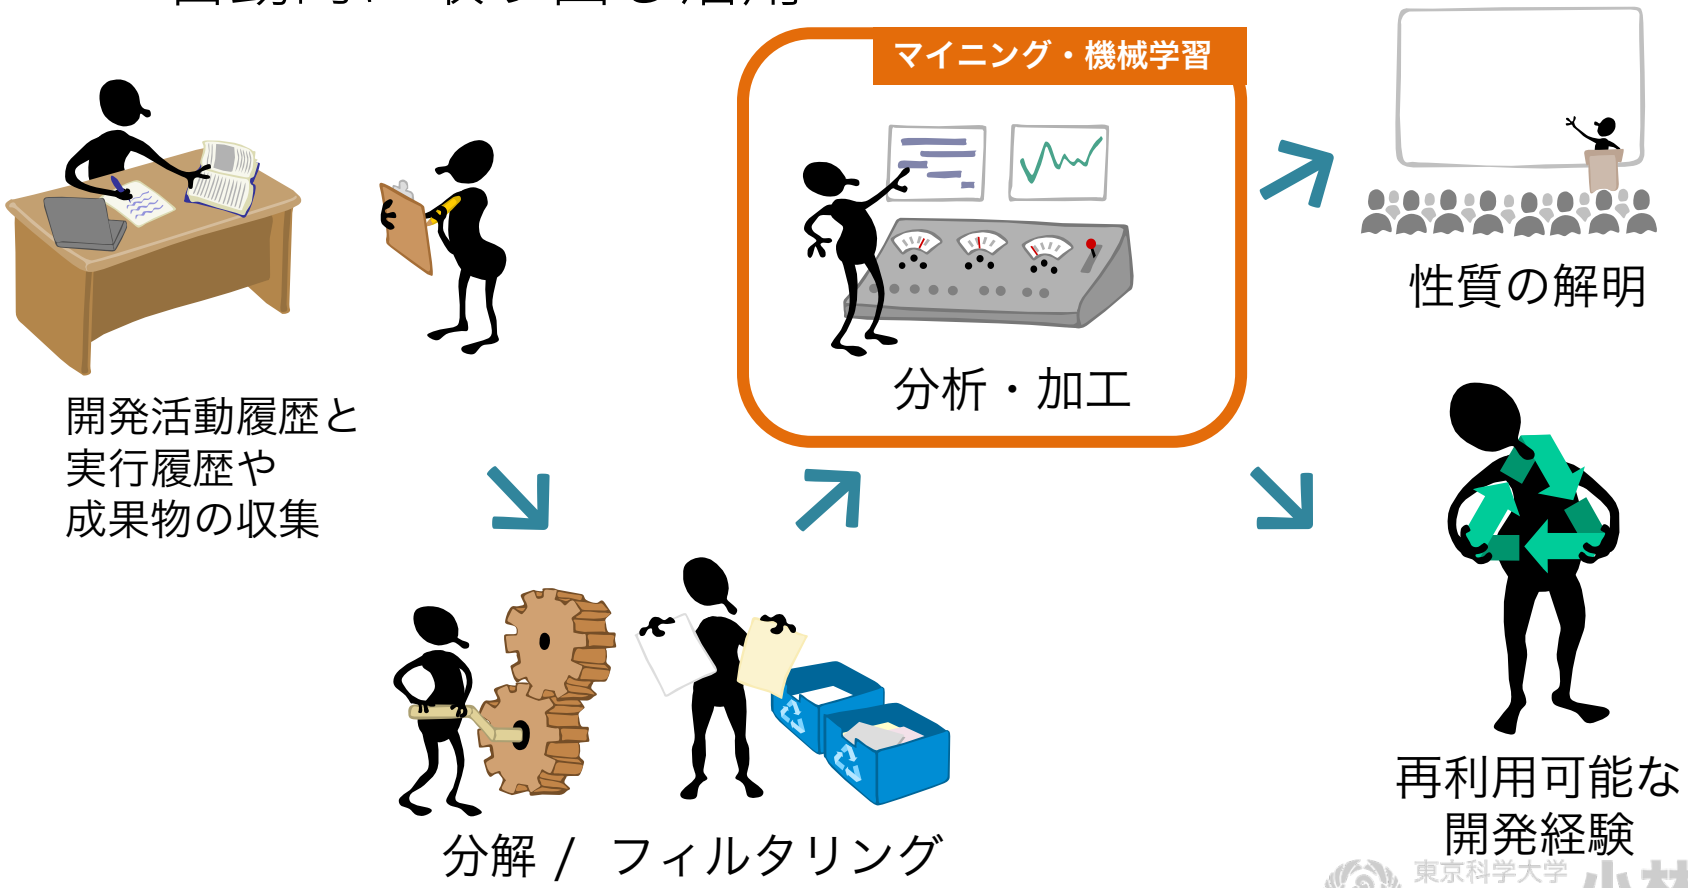

既存データからの経験抽出

- マイニング・機械学習・統計処理を応用

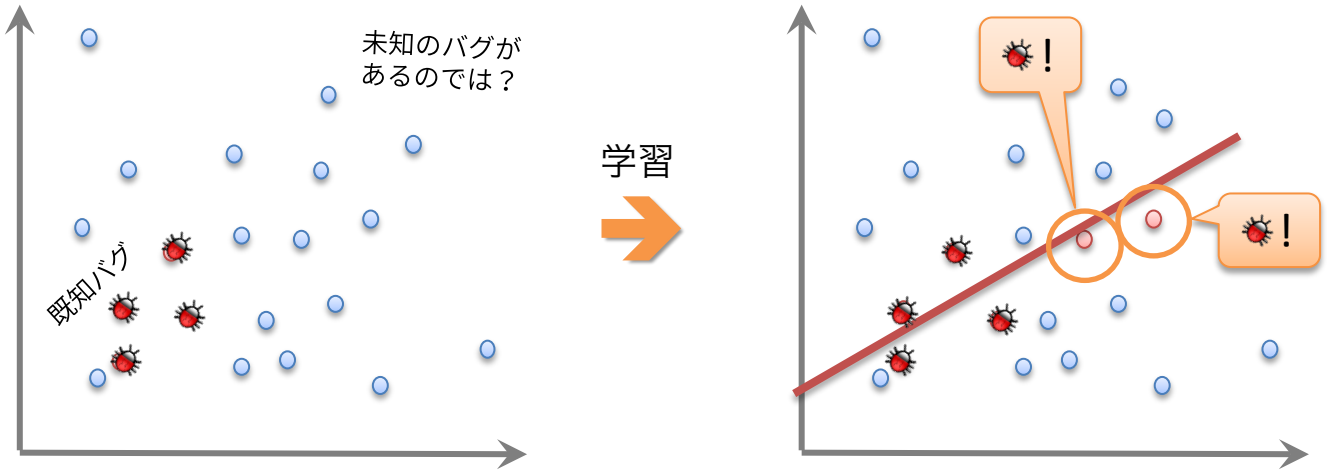

- 様々な技法を用いて経験を抽出

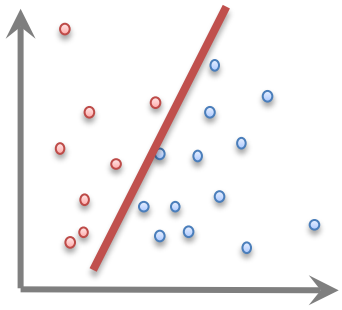

分類

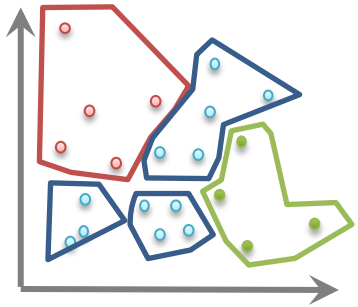

クラスタリング

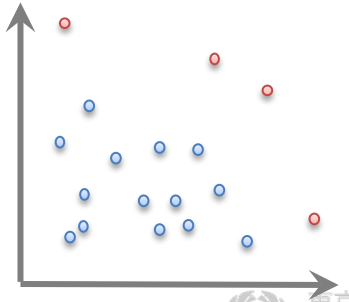

外れ値検出

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
  - 保守＝既存のソフトのデバッグ・改修
    - バグの箇所を特定し，取り除くための支援
  - 進化＝既存のソフトへの機能追加・改善
    - 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

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

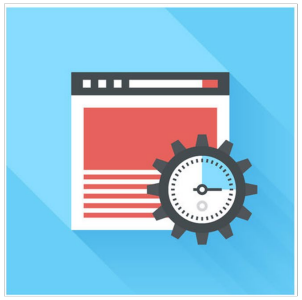

実行情報の抽象化・可視化
実行時のプログラム挙動を分かりやすく提示

バグ防止：変更漏れ発見

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)

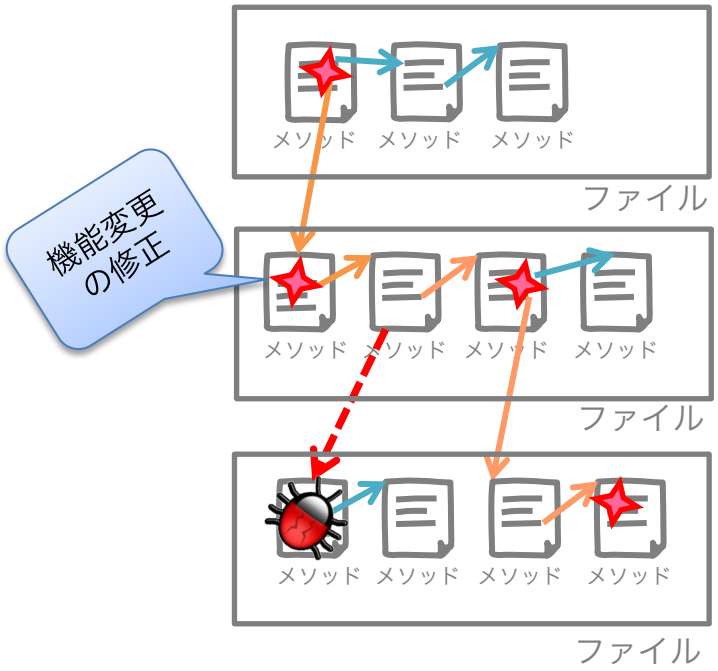

- 静的解析で波及先の特定は(ある程度)可能
  - コードが必須＝フレームワークなどを介すると分断される
  - ポインタ・動的束縛は「可能性」
- 全ての静的依存に波及するわけではない
  - 不要な関係が多いという報告

「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？

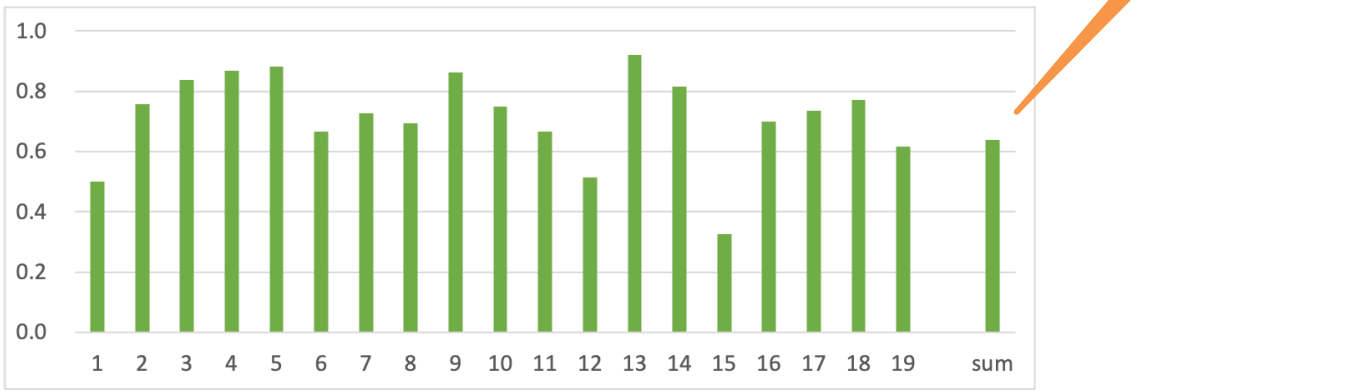

指摘可能な変更忘れファイルの割合

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

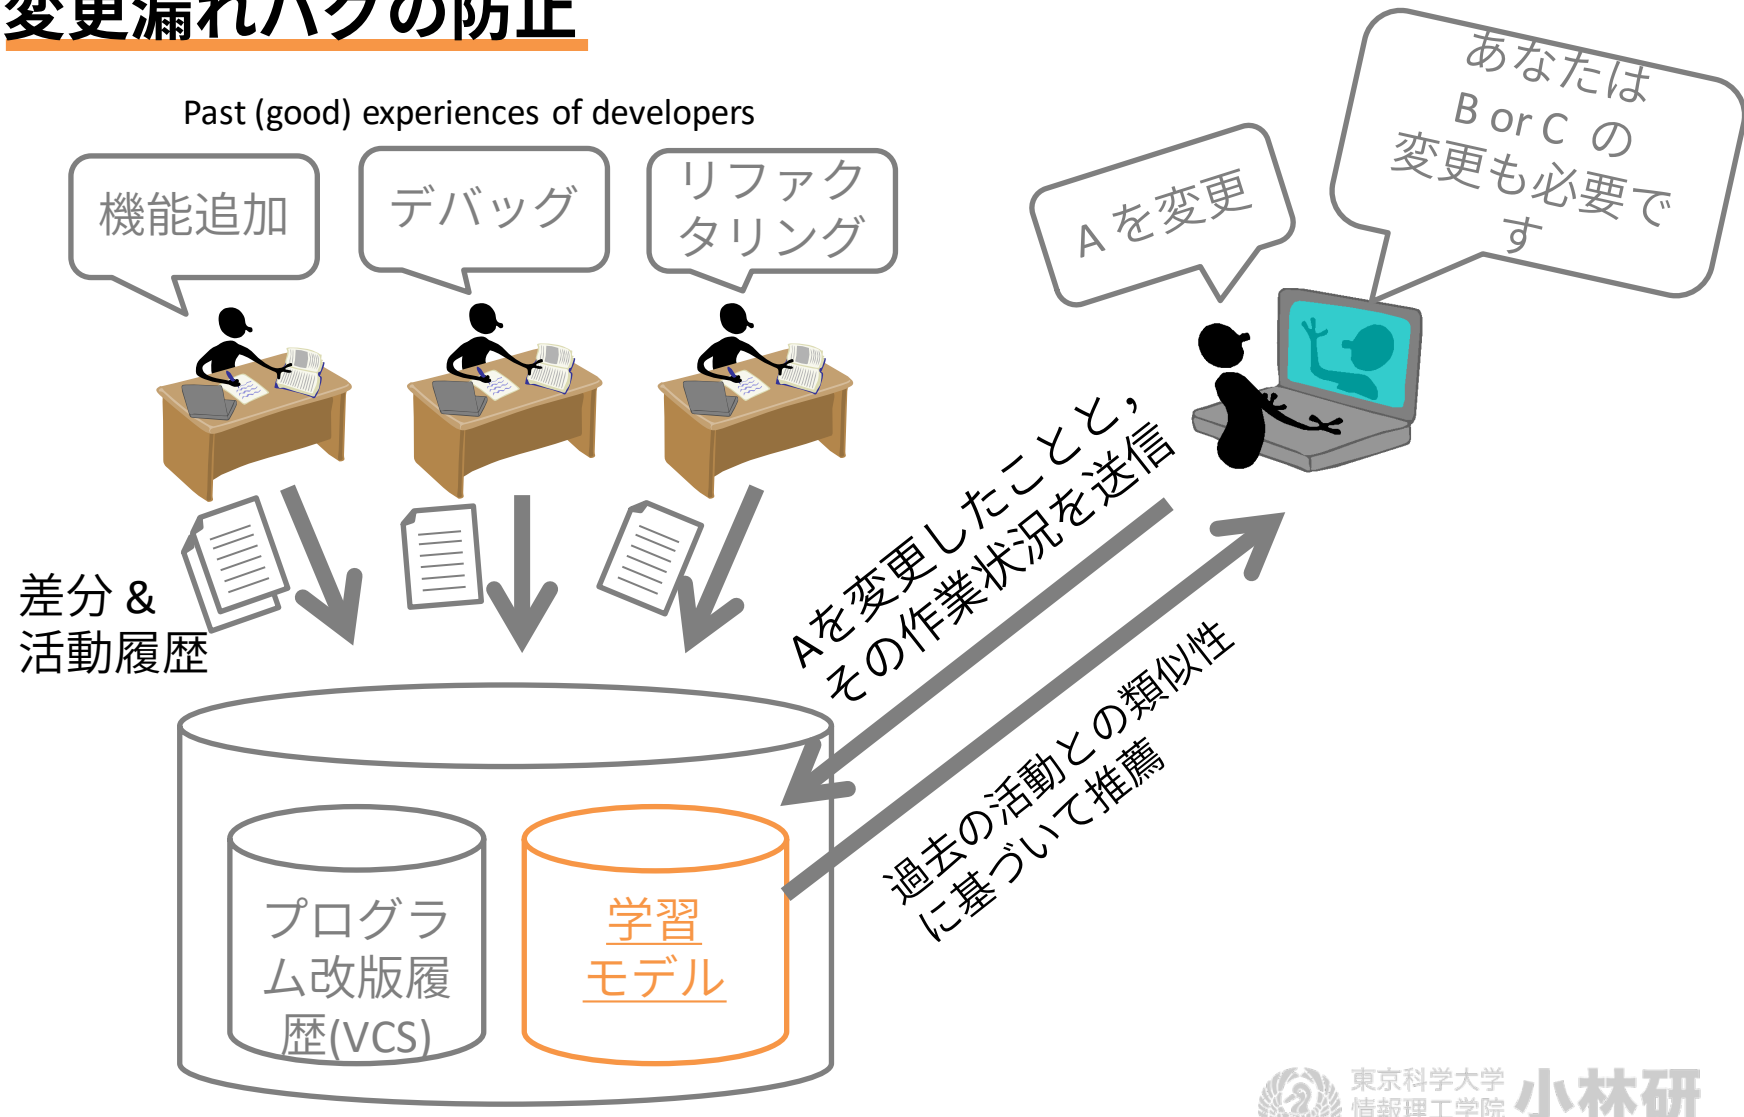

変更支援手法：ツールの出力例

```
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 wi...
  +-------------------------------------------------------------------------
  |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：ChatOps環境への組み込み (共同研究)

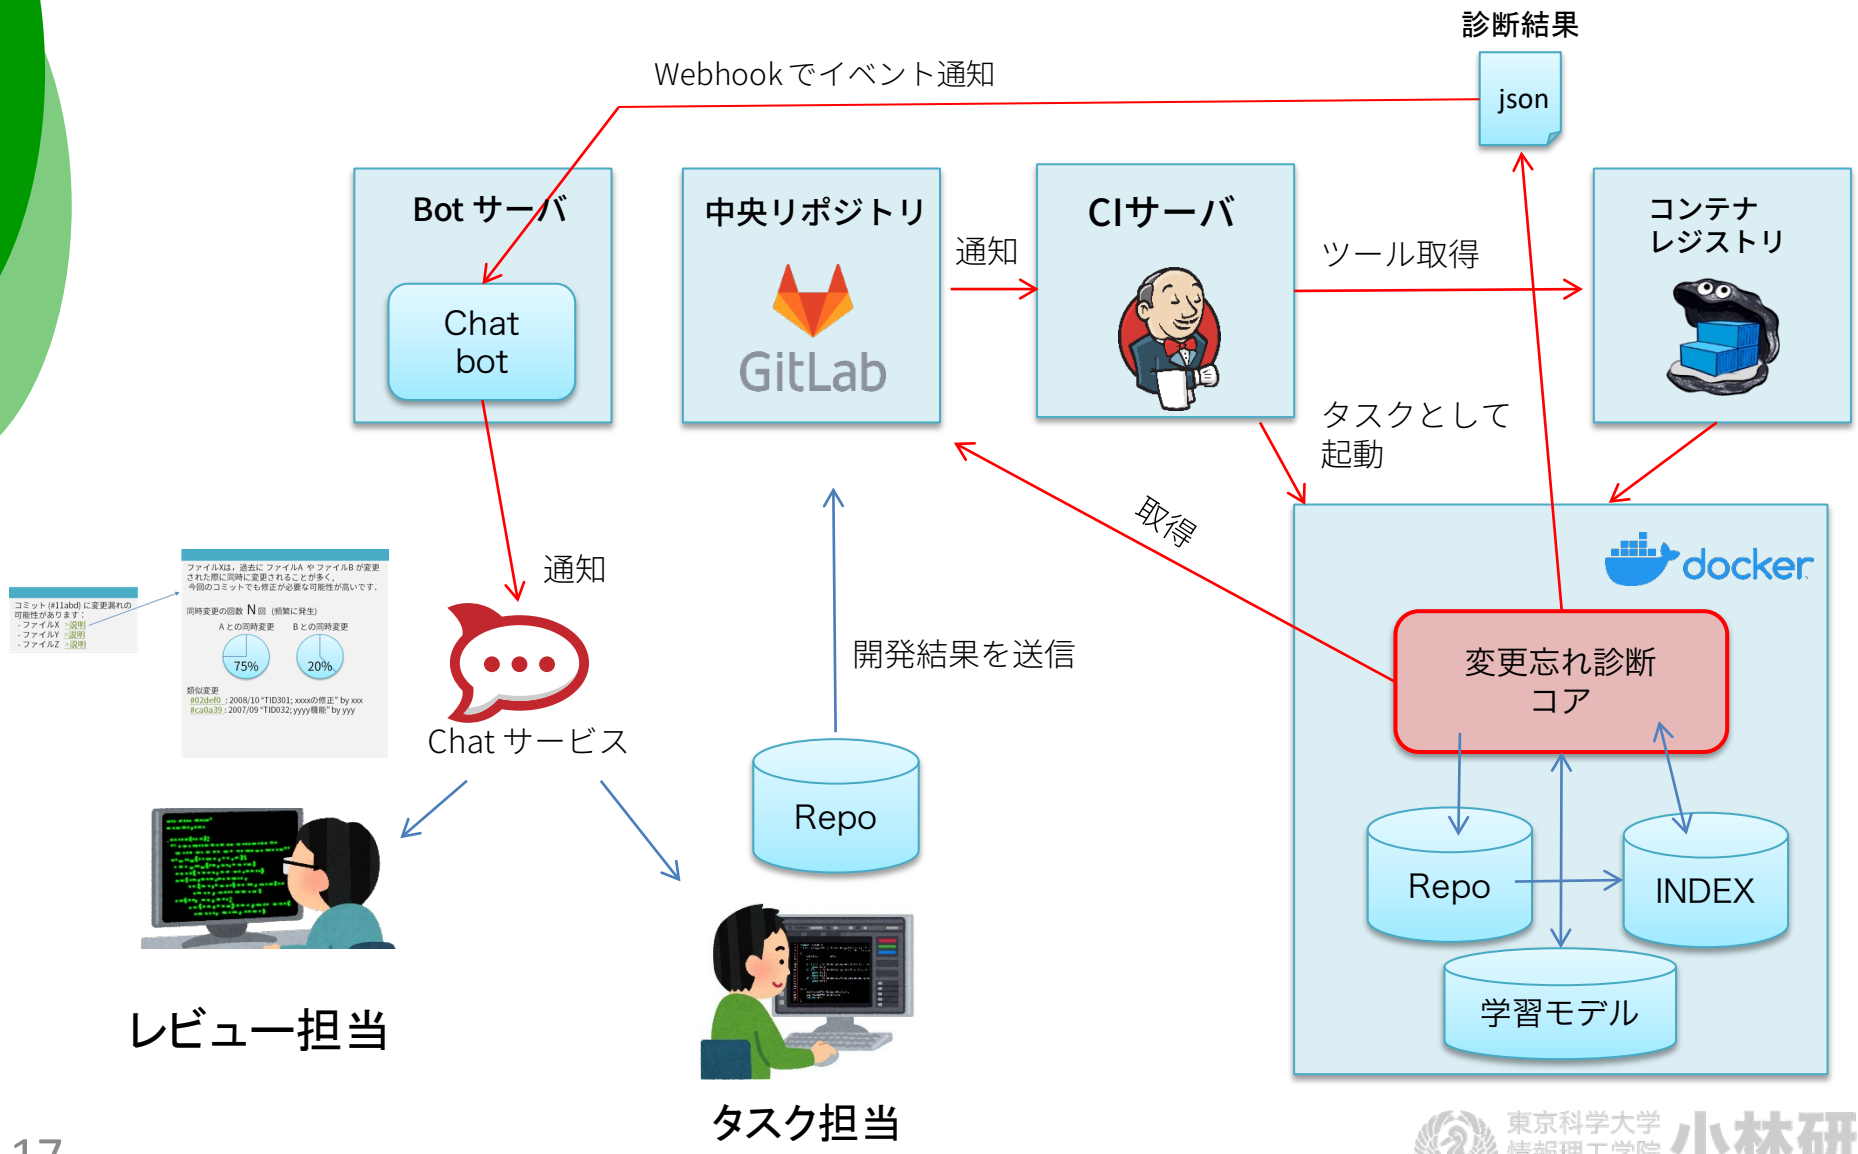

より詳細なマイクロプロセスの抽出

- **操作履歴** の解析に基づく変更推薦
  - 操作履歴：Commit間に「どんな操作をした」か

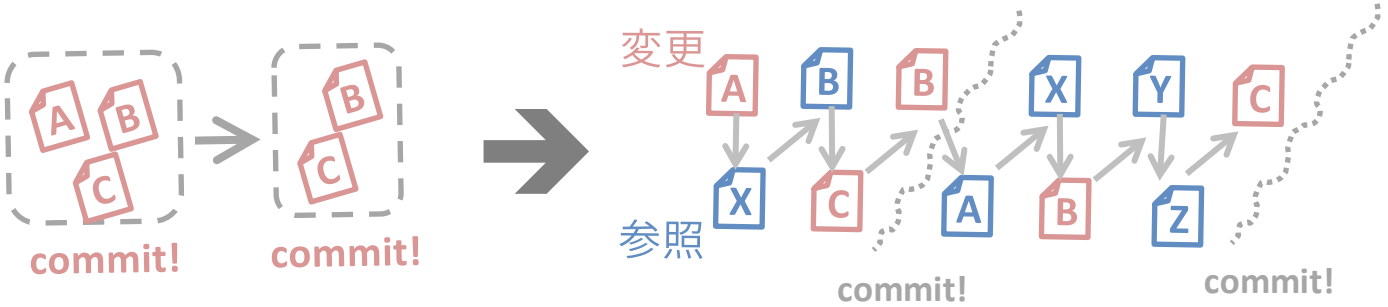

変更履歴 ＝ スナップショット　　操作履歴 ＝ 開発者がどのように変更したか

  - 参照先や変更の順序から，「変更の文脈」を抽出
    - 「ファイルXを変更する」には複数の意図がある
    - 仮説：文脈が類似するならば変更意図も類似する

- 国際会議 MSR のコンテスト題材になるなど，
  操作履歴分析は（ようやく）着目されてきた

より詳細なマイクロプロセスの再利用実験

- 過去の開発経験を応用できるか？
  - 学生 17 名で「陽気な配管工が活躍するゲーム」を拡張
  - 例：Hammer Marioの導入，パックンフラワーが炎をはく
- 開発活動を記録して学習
  - どのファイル・関数を参照・変更したかを記録
  - 次の変更を予測できるか？を評価
- 現在までの結果：結構当たる!

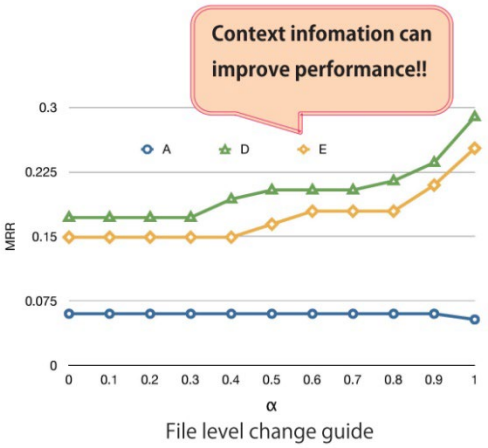

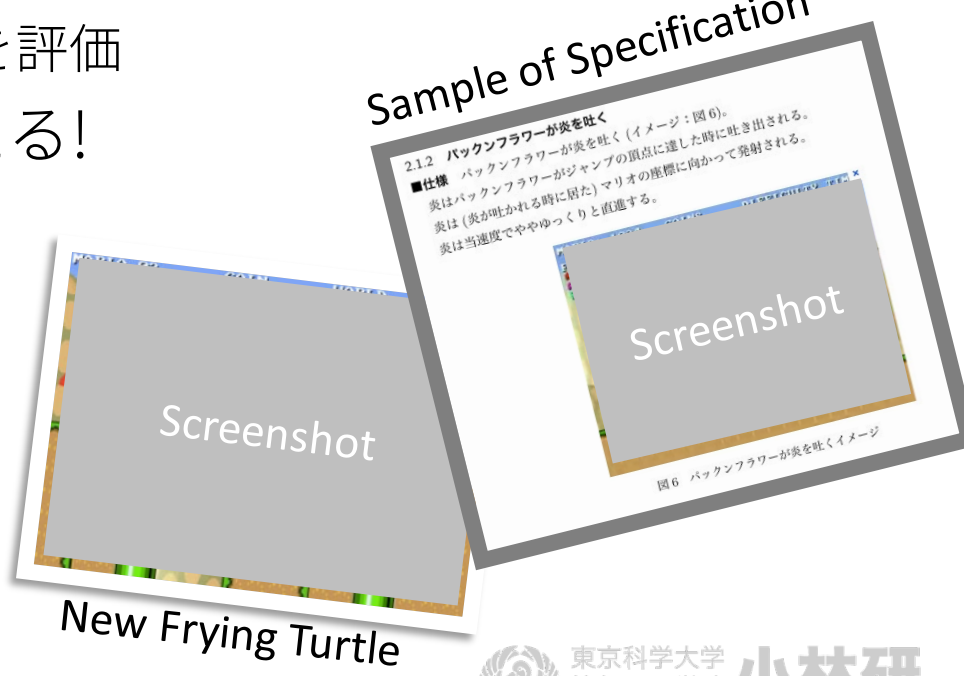

変更支援手法：国際共同研究への発展

- 開発者の活動分析 (2014)
  - スイス Lugano大 と実施
  - 操作ログを持ち寄り分析
    - Java: 15名，SmallTalk 7名
  - 発見：70+%を 理解に費やす
    - それまで定説では 35%程度

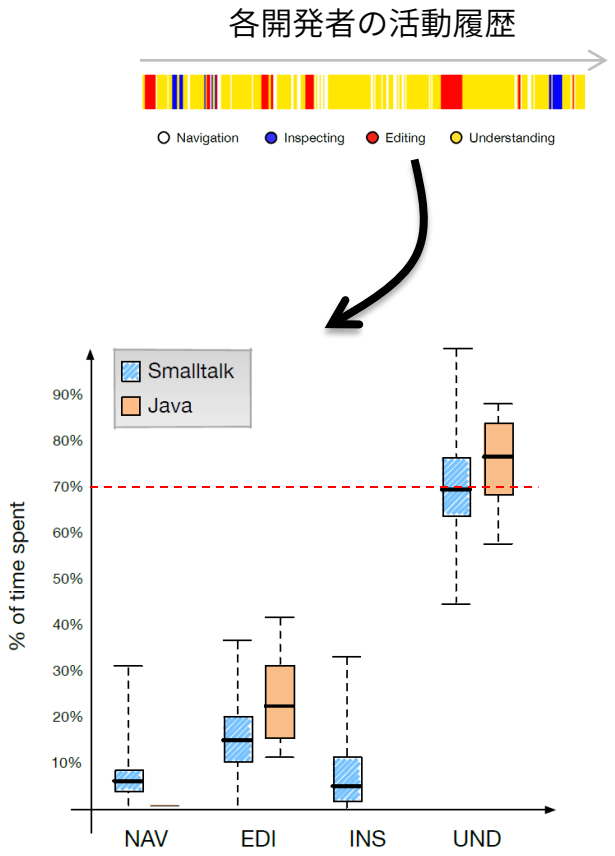

- 長期開発データの分析 (2017)
  - ノルウェー Oslo大と実施
  - 4名の企業開発ログを分析
    - 先方は別の目的でログを取得

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

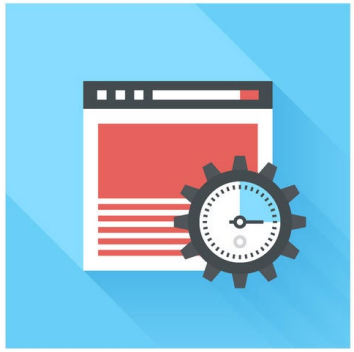

実行情報の抽象化・可視化

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
  - 情報検索によるバグ箇所特定 (2020〜)
  - 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〜)

デバッグ支援：
バグ発見・原因箇所特定

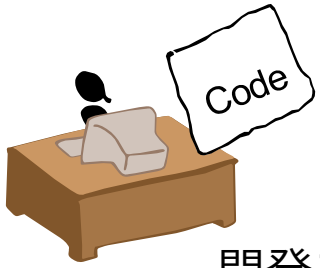

テスト

開発フェーズ

バグ報告

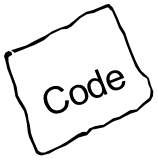

リリース

監視

運用フェーズ

テスト失敗
(仕様違反の実装)

挙動: 想定違反
再現条件：既知

テスト不足
(仕様違反の実装)
(想定外の現象)

挙動: **報告次第**
再現条件: **未知**

テスト不可
(仕様化が困難)

挙動: **異常/危険状態に到達**
再現条件: **未知**

小林研で扱う
主な範囲

コード中の
バグ箇所は
どこ？

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

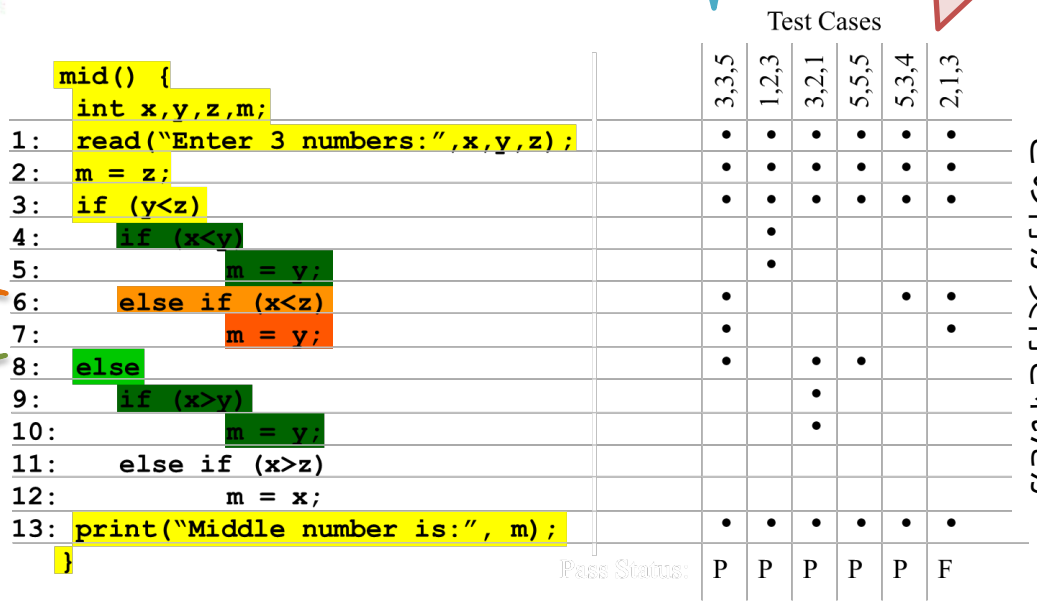

[Jones+2002] Jones et al. "**Visualization of test information to assist fault localization**" in Proc. ICSE2002
図は http://pleuma.cc.gatech.edu/aristotle/Tools/tarantula/vizworkshop.ppt Slide p12 より. 引用

バグ箇所の候補の絞り込み

- 情報検索ベースのバグ局所化手法
  - 「ソースコードの検索問題」とみなす
  - ヒント(クエリ)＝バグレポート記述
- 誤検出をどのように減らすかがポイント

この部分が研究領域

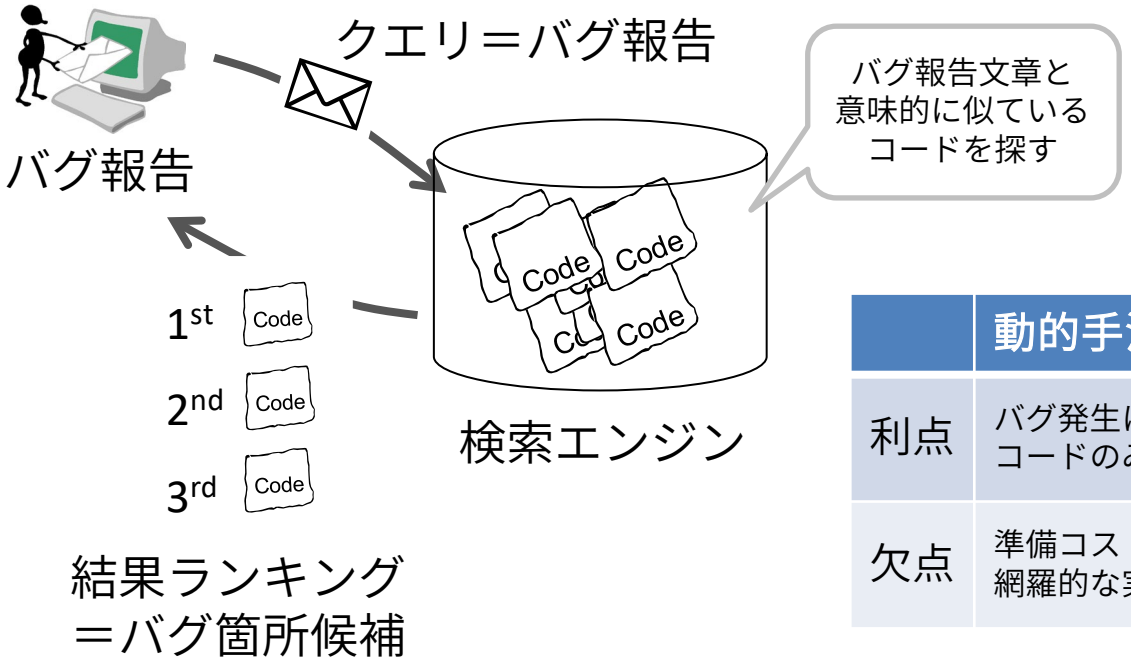

	動的手法	静的手法
利点	バグ発生に関係するコードのみが対象	**導入が容易(準備コストが低い)**
欠点	準備コストが高い 網羅的な実行が必要	**誤検出が多い**

文芸的デバッグ環境

- 新しいデバッグ支援環境 JISDLab を開発

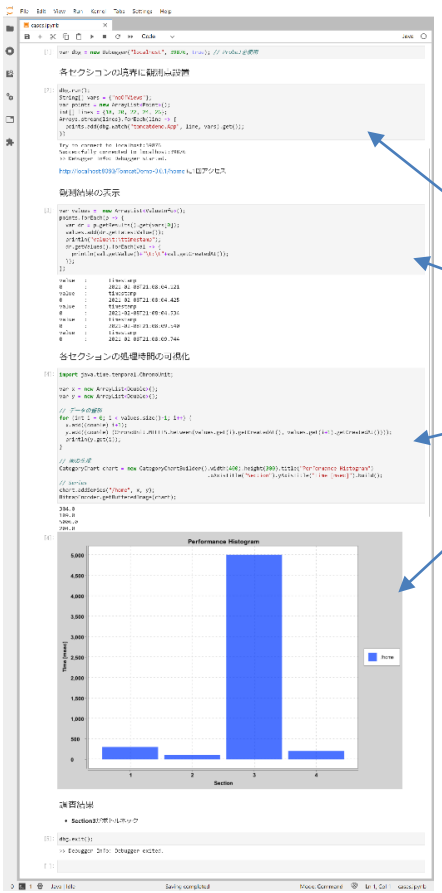

- 観測の影響を最小限に
  - 実行を停止せずに観測
  - 実行中に「観測したい値」を変更可能
- Scriptable Debugging + Literate Program
  - デバッグ作業をスクリプト記述
  - 観測結果の加工・保存も可能
- “実行できるバグレポート”の実現
  - 不具合の再現・状況確認・解析を可能に

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

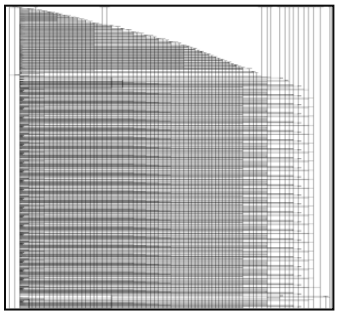

生成したシーケンス図

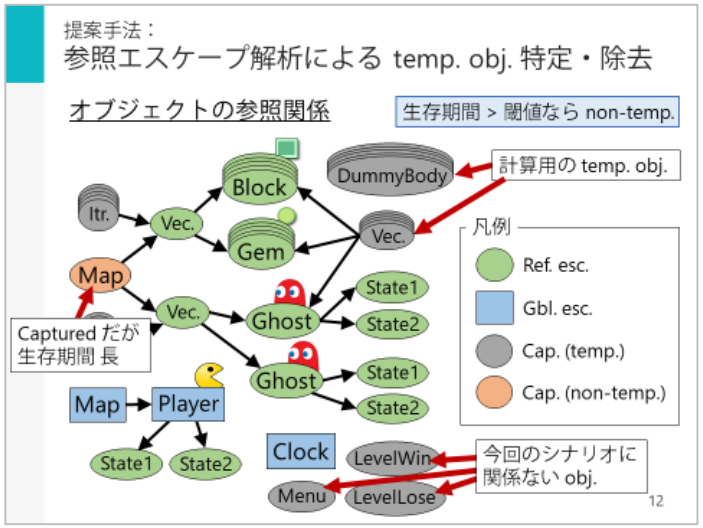

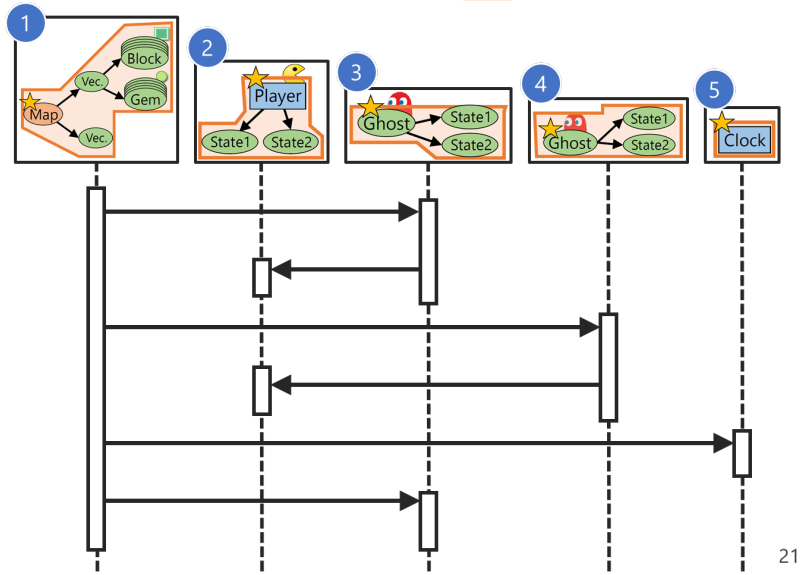

提案手法で生成する実行概要シーケンス図

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

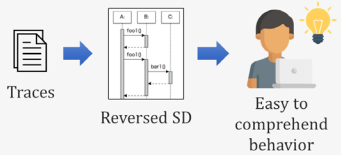

Real

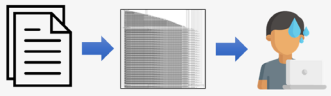

Existing tools…
- Sometimes **Crash**
- **Hard** to **re-use**

… etc.

Interactive Loop Summarization

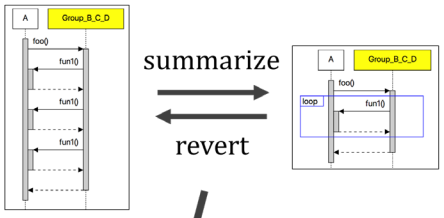

Interactive group folding/unfolding

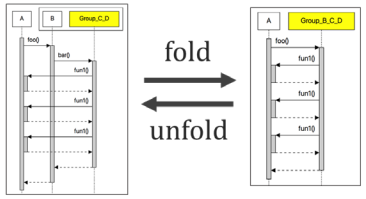

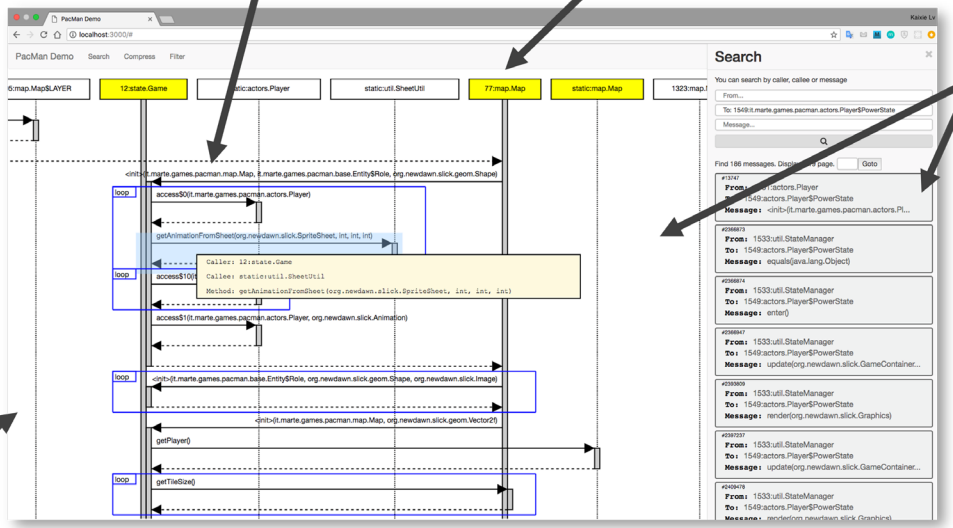

Rich features for exploration
- Searching
- Filtering
- Zooming

… etc.

Operation Logging

Records interactions to support user activities analysis.

Browser-based tool
- Easy to use
- Platform-free
- Embed to Web page

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：コード要約

- 保守工程の大半は「コードの理解」
  - ドキュメントは欠損・整備不良が多い
  - 「可読性の高いコードを書く」が唯一の対応策
- 新しい流れ：ドキュメント生成・コード要約
  - コード・コミットから「ドキュメント」を生成
    - 既存手法の多くは抽象度が低い (例: Javadoc API reference)
    - 文書要約技術を応用した「要約」の生成がトレンド
  - 欲しい情報は多種多様
    - このコミットで何を変更したの？
    - このパラメータをONにすると何が起こるの？
    - このAPIどう使うの？
    - このアプリどんな機能があるの？
    - この機能どこでどうやって実現されているの？

これまでの取り組み：SE 4 IaC

- 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
  - …

これまでの取り組み: Dockerfileの保守支援

- CDCM: Continuous Dockerfile Configuration Management
  - 構成再現性を担保：正確な外部依存先を記録
    - 意図しない外部依存先の変化も検知・指摘

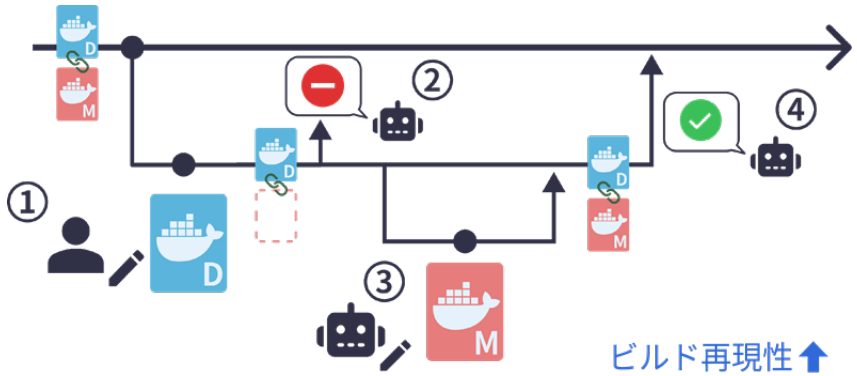

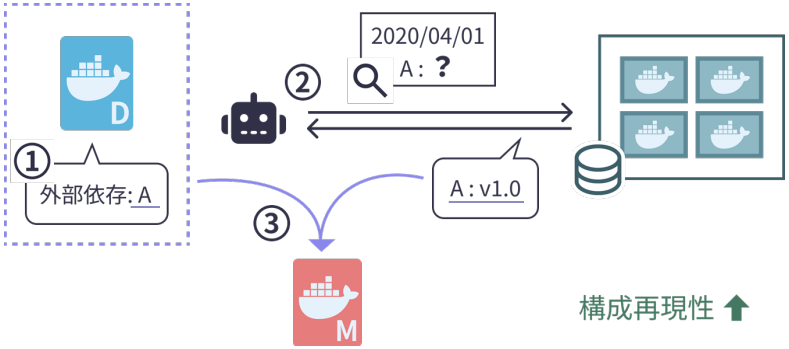

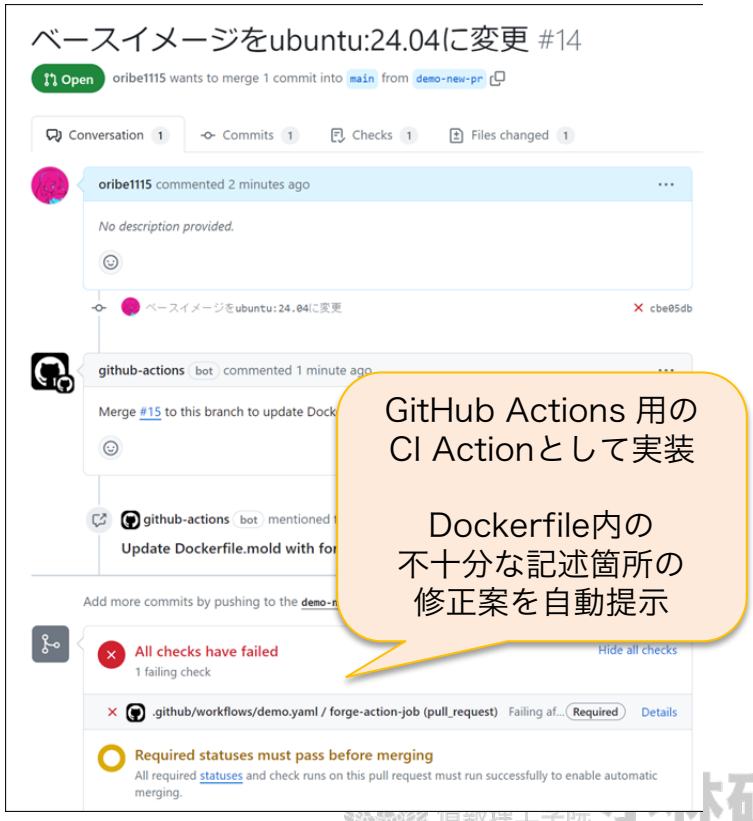

2025年度メンバー

- 学生は13名前後
  - 教員：小林，助教
  - D : 0-1名
  - M2：6名
    - コミット自動分割，WebUIテスト共進化，デバッガ，IDE拡張，ドキュメント生成，変更推薦
  - M1：3名
    - バグ箇所特定，コミットメッセージ生成，未定 x 1
  - 学部：1-3名
  - 短期滞在・交換留学： 若干名

例年修士は 3〜4名/学年
他大学からの
入学は例年半数程度

- 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，はこだて未来大，スイス Lugano大，濠 Adelaide大
  - 企業：IT/SI企業 3社

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)

４月入学修士のスケジュール

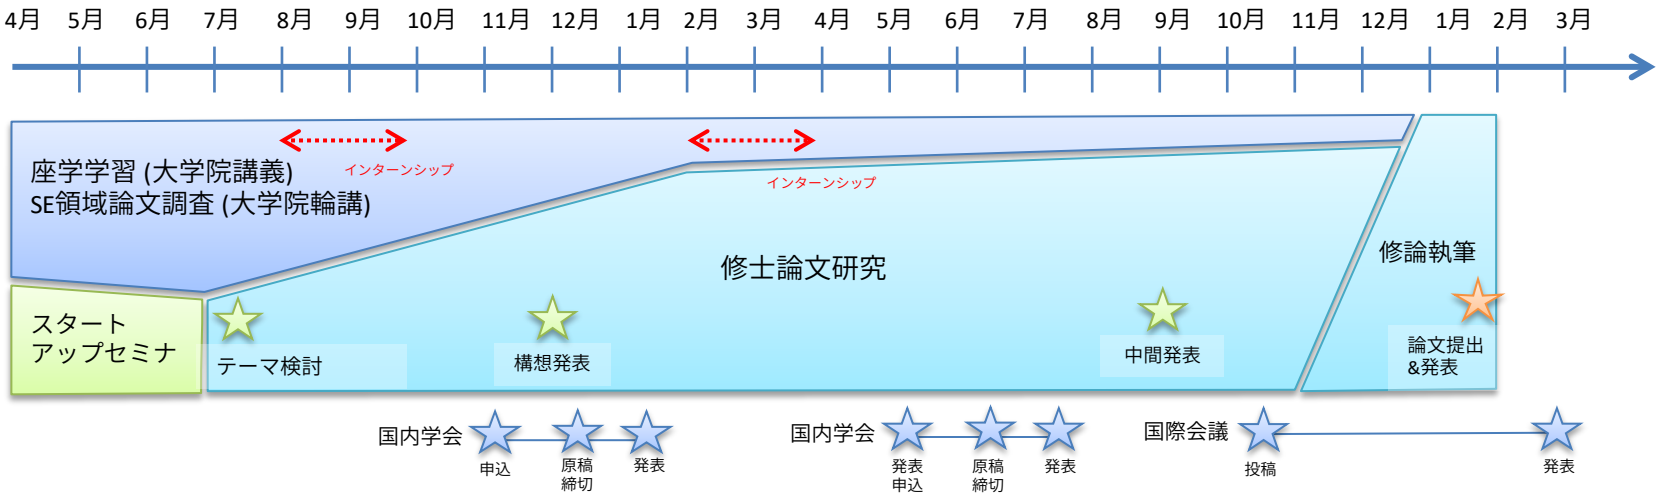

- 基本スケジュール
  - **週3日間のコアタイム制をとってます**
    - 研究室にいれば研究が進むわけではないですが，来ないと全く進みません．
  - 大学院輪講(週2時間)，研究会 (週2時間) に参加
    - 前期はこれに加えて スタートアップセミナー(1.5h*8回程度)に参加
  - 大学院輪講は論文紹介が基本
  - M1後期から研究会で毎週進捗を確認

特課研生のスケジュール

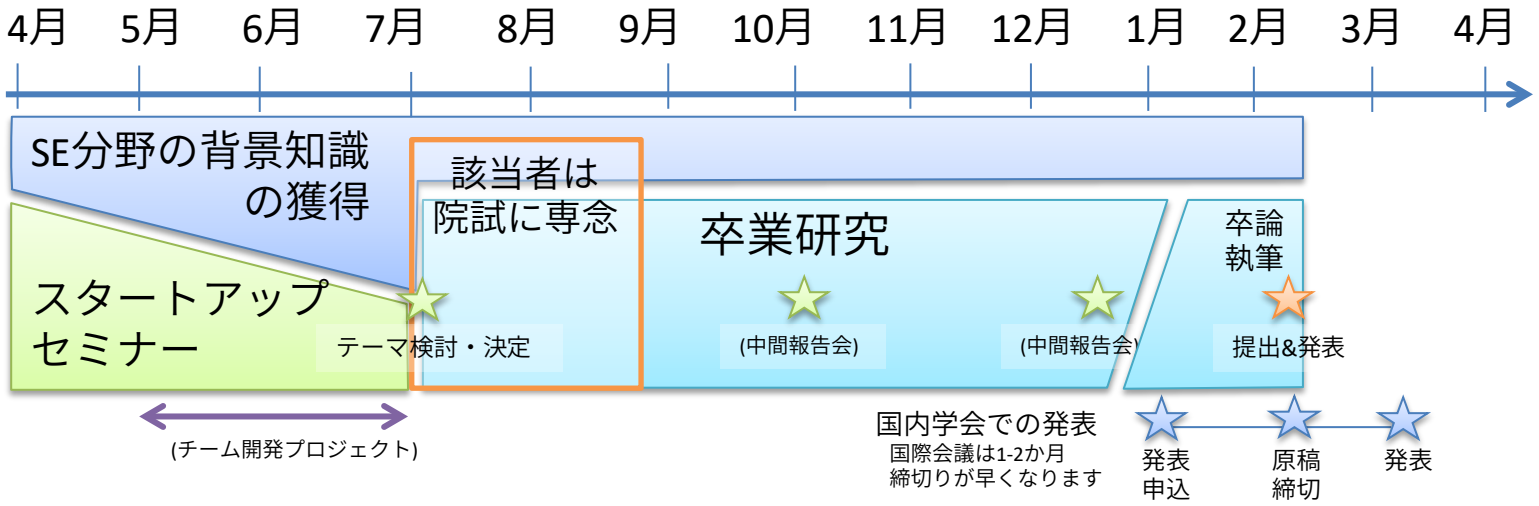

- 基本スケジュール
  - **週3日間のコアタイム制をとってます**
  - 大学院輪講(週2時間)，研究会 (週2時間) に参加
    - 前期はこれに加えて スタートアップセミナー(1.5h*8回程度)に参加
  - 後期の輪講は洋書輪読か論文紹介
  - 8月~9月中旬程度までは 輪講・研究会はなし (≠ 夏休み)
    - 上の図の通り，9月一杯「休む」と研究は2か月程度しかできない
  - 後期から研究会で毎週進捗を確認

小林研の「特課研」に対する考え

- 「研究」に関する基礎能力の向上 が主目的
  - 文献調査・実験（計画と評価方法）・論文執筆・発表
    → テクニカルライティング，ロジカルシンキング，
    プレゼンテーション
  - 上記能力に関連するスタートアップセミナーを予定
    - 座学→体験による定着 を行いたい
    - 卒研発表会だけでなく，研究成果の学外発表を推奨
  - 当然，研究内容はおろそかにしません
    - 多くの卒論生は3月~修士在学中に学会発表
    - 国際会議で発表・学会で受賞したケースも少なくない
- SE分野，特に設計～保守に関する専門知識の獲得
  - 実質4か月程度しかないが，背景知識の獲得は目標としたい．
  - 研究指導，関連論文・書籍の提供を通じた学習がメイン

東京科学大学
情報理工学院 **小林研**
Software Analytics Research Group

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@comp.**isct.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
https://www.**sa.cs.**titech.ac.jp/