AI時代のテスト技術

国立情報学研究所　石川　冬樹

http://research.nii.ac.jp/~f-ishikawa/

大学共同利用機関法人 情報・システム研究機構
国立情報学研究所
National Institute of Informatics

自己紹介

- ソフトウェア工学と先端自律・スマートシステム
  特に品質・ディペンダビリティに関する技術
  - 形式手法，テスティング，自己適応，
    最適化，要求分析，安全性論証など
  - サービス合成（クラウド・IoT），CPS/AI（特に車）
- 産業界向け教育・応用研究
  - トップエスイー，日科技連SQiP，電通大社会人博士
- 最近（1）：自動（運転）車ソフトのテスト
- 最近（2）：機械学習ベースAIのテスト・品質

機械学習工学研究会
MACHINE LEARNING SYSTEMS ENGINEERING

AIプロダクト
品質保証
コンソーシアム

おまけ：形式手法の産業応用

- 使っている人は使っている
  - クラウド内部の複製管理：網羅的な検査，1チームの成功から組織に展開（AWS）
  - モバイルアプリ：メモリリークに関する静的解析をリリースサイクル上で自動起動（Facebook）
  - 自動運転地下鉄やホームドアのコア部分：正しさの証明済みコードを生成，単体テスト不要に（ClearSy）
  - 組み込みチップ：複数組織に展開する外部仕様を厳密化，テスト，仕様に起因する不具合をゼロに（FeliCa）

[C. Newcombe et al., How Amazon Web Services Uses Formal Methods, Comm. of the ACM'15]

[C. Calcagno et al., Moving Fast with Software Verification, NFM'15]

[J. Abrial, Formal Methods in Industry: Achievements, Problems, Future, ICSE'06]

[T. Kurita et al., Practices for Formal Models as Documents: Evolution of VDM application to "Mobile FeliCa" IC Chip Firmware, FM'15]

とはいえ

- 開発対象全体の全問題に対処できるわけではない
- スケーラビリティに懸念
  - 特に，連続系・物理的挙動を扱う場合
- というかUML/Simulinkモデルやコードしかない
  - （厳密に意味論が与えられた）モデルは（最新で）ない
- 今のやり方を変えられない

  （上流にかける工数，エンジニアスキル，などなど）
  - 費用対効果には不確かさが多く踏み込めない
  - 移行コストを乗り越えられない

ということで,

私からは「力業」「テスト」の話を

実行しまくって確認する！

「試行＆評価」サイクル！

キレイに言うと

「発見的・経験的アプローチ」

関連動向：

「AIによるテスト」（の一種）

ソフトウェアテスティング分野の一潮流

- サーチベースドテスティング（Search-based）
  - 最適化技術（特に進化計算・メタヒューリスティック）により「欲しいもの」を表すスコアを最大化するようなテストスイートやテストケースを生成
    - 例：「車が人に最も近づくような危ういテスト」ケースを生成
    - 例：「前バージョンと比べ出力が大きく変わる」入力を発見
    - 例：「高カバレッジで数が小さい」回帰テストスイートを生成

「試行＆評価」サイクル！

[S. Ali et al., Systematic Review of the Application and Empirical Investigation of Search-Based Test Case Generation, 2010]
[http://www.evosuite.org/]

おまけ：サーチベースドテスティングのレベル

- 2018年のJava Unit Testing Competition
  - 比較用に複数ツールを組み合わせた「最強ツール」は，人が作ったものよりよいテストスイートを10秒で生成
  - ここでの評価基準は，コードカバレッジとミューテーションスコア（人工バグの検出率），テストケース数
- Facebookでの事例
  - モバイルアプリのContinuous Integrationに組み込み
  - テスト数が少なく，コマンド数が短く，多くのクラッシュを報告するようなテスト一式をまとめあげる
  - サーチベースドのバグ自動修正ツールも連動

[https://github.com/PROSRESEARCHCENTER/junitcontest/blob/master/README.md#6th-junit-contest]
[Molina et al, Java Unit Testing Tool Competition - Sixth Round]

[https://code.fb.com/developer-tools/finding-and-fixing-software-bugs-automatically-with-sapfix-and-sapienz/]

形式手法分野での一潮流

■検証式の定量化

シミュレーション結果例（２サンプル）

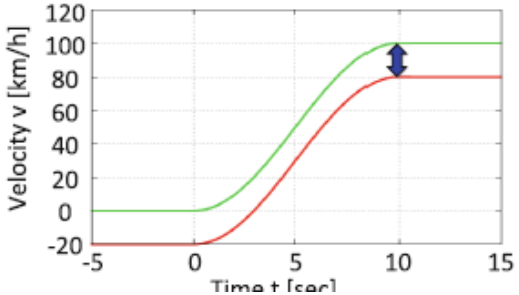

イベントBが起きてから10秒以内に
速度は 80km/h 以上になる

[Fainekos et al., Robustness of temporal logic specifications for continuous-time signals, TheoCompSci'09]
Figure from [Akazaki et al, Time Robustness in MTL and Expressivity in Hybrid System Falsification, CAV'15]

形式手法分野での一潮流

■定量検証式の定量的な充足評価

シミュレーション結果例（２サンプル）

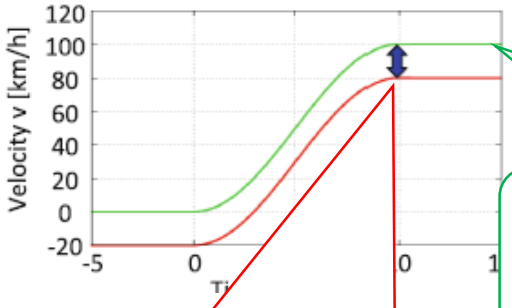

イベントBが起きてから10秒以内に
速度は 80km/h 以上になる

OK！10秒後，求められたよりも20km/h余裕を持って

ロバストな充足

OK！10秒後，ちょうどギリギリ求められた値クリア

危うい充足（違反に近い）

（時間についても同様な議論ができる）

[Fainekos et al., Robustness of temporal logic specifications for continuous-time signals, TheoCompSci'09]
Figure from [Akazaki et al, Time Robustness in MTL and Expressivity in Hybrid System Falsification, CAV'15]

形式手法分野での一潮流

■定量検証式に対する最適化を用いた反例探索

シミュレーション結果例（２サンプル）

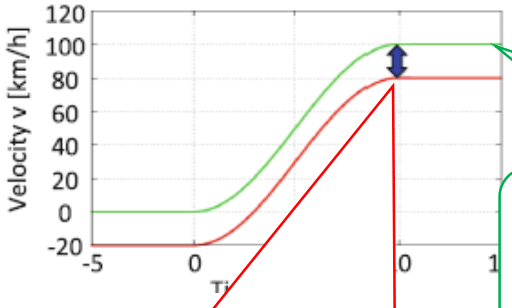

イベントBが起きてから10秒以内に
速度は80km/h 以上になる

OK！10秒後，求められたよりも20km/h余裕を持って

ロバストな充足

OK！10秒後，ちょうどギリギリ求められた値クリア

危うい充足（違反に近い）

「試行＆評価」サイクル！

（時間についても同様な議論ができる）

➡「ロバスト度合い」の最適化問題に帰着

[Fainekos et al., Robustness of temporal logic specifications for continuous-time signals, TheoCompSci'09]
Figure from [Akazaki et al, Time Robustness in MTL and Expressivity in Hybrid System Falsification, CAV'15]

AIによるテスト：

自動車関連の研究事例

（ものすごく簡単な）問題イメージ

Simulinkモデル：
自動ブレーキ付の車の挙動

入力

ユーザの挙動
- アクセルペダル
- ブレーキペダル

環境
- 初期速度
- 歩行者の位置・動き
- 路面状況
- …

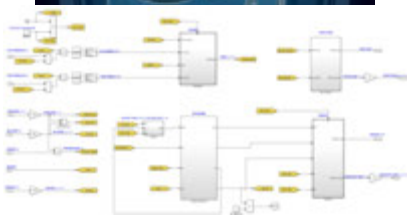

出力
- 衝突有無
- 衝突速度

- *実行可能なものがある（シミュレーションモデルやコード，実機）*
- *一つの入力を決めて，出力を得ることはできる*

➡ *「危ない」ケースを見つける*

・・・だけではなく何をする？

研究事例：より探索的な反例探索

- 系統的な探索手法を適用
  - たまたま見つけた悪い例に深入りしない
  - 探索空間全体に対する情報を随時管理・更新
- Monte-Carlo Tree Search
  - 囲碁プレーヤの構築などで有名なAI技術
  - 連続変化する入力シグナルを分割，「匂い」「怪しさ」を継続記録し「試行＆評価」サイクル

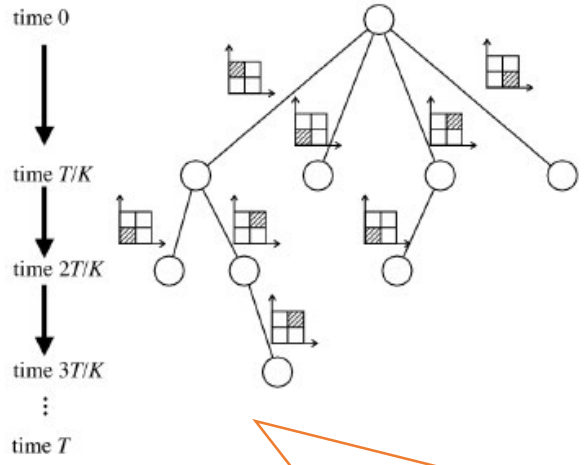

最初にアクセルを踏み込んだらどうだろうか？その次は・・・

[Zhang et al., Two-Layered Falsification of Hybrid Systems Guided by Monte Carlo Tree Search, EMSOFT/TCAD'18]

研究事例： 事前訓練による反例探索

- 探索方法を学習
  - 毎回ランダムから探索するのを避ける
  - 囲碁プレーヤが様々な相手に対し事前訓練するように
- モデルファミリー式に対する反例生成器の構築
  - 試行錯誤の度に行う検査を高速に
  - 設計や環境の多少の変化があっても高速に検査

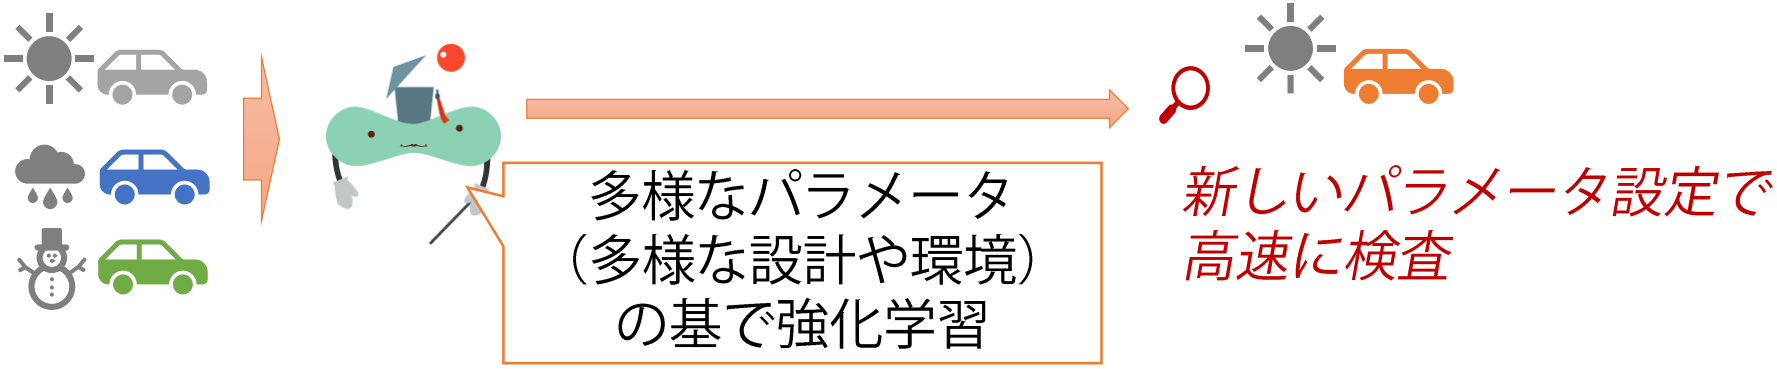

[Kato et al., Falsification of Cyber-Physical Systems with Reinforcement Learning, MT-CPS'18]

研究事例： 安定性（敏感性）分析

- 不安定なパラメータ領域を探索

  *パラメータ値の少しの変更が安全や品質に大きく影響する*ような状況を報告

  - 設計パラメータ（避けるか重点的にテスト）も，
    環境パラメータ（重点的にテスト）も

動き出し時間設定の
0.12 秒の差により，
衝突無しの状況が
20km/h衝突に変わる

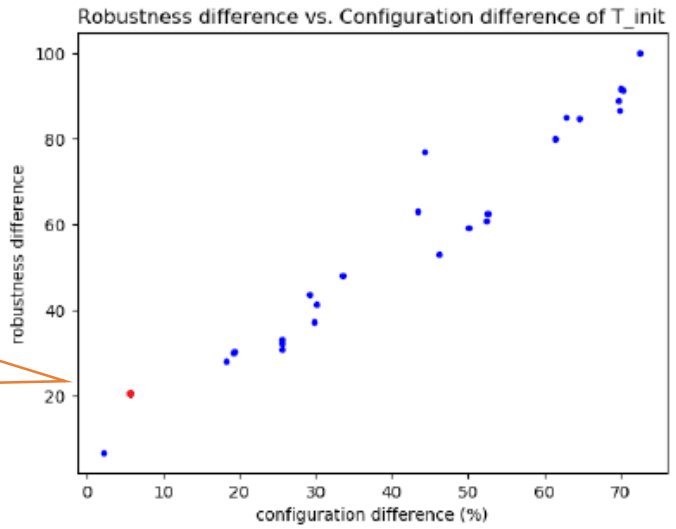

[Lee et al., Stability Analysis for Safety of Automotive Multi-Product Lines: A Search-Based Approach, GECCO'19]

システムレベルへ発展中

- 自車の経路を定める部品

[Figure from McNaughton, Parallel Algorithms for Real-time Motion Planning]

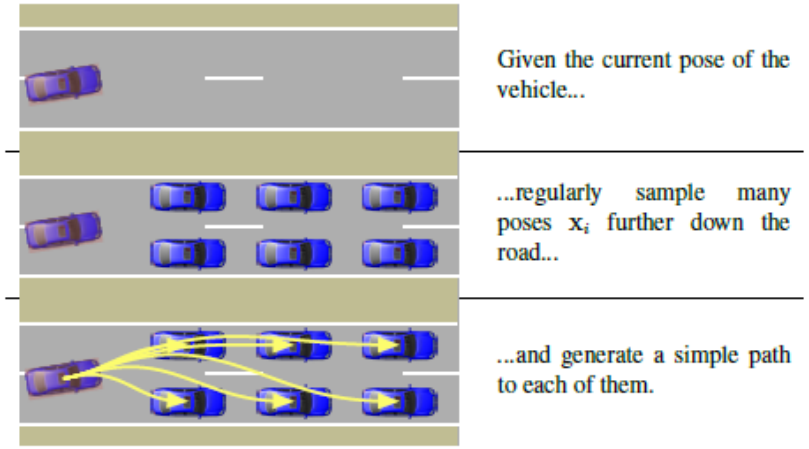

- 障害物との距離，レーン遵守，車両の物理的限界，なめらかさ・快適さ，法令遵守，運転慣習遵守，・・・
- 道路形状，歩行者・他車の位置や動きなどを設定してシミュレーション実行

➡ *膨大な可能性（シミュレーション設定）の中で「意味のあるテスト」への探索も同時に*

おわりに

機械学習ベースAIシステムのための深化

- 自動運転・物理系に限らず最近の重要課題
  - 例： 機械学習工学研究会キックオフシンポ（18/5/17）
  - 例： Open QA4AI Conference
    QA4AIガイドライン初版リリース（19/5/17）

機械学習工学研究会
MACHINE LEARNING SYSTEMS ENGINEERING

AIプロダクト
品質保証
コンソーシアム

- 発見的・経験的テストの応用は世界的にも注目
  - 例： 誤認識が起きる方向にノイズの足し方を寄せていく

- 様々な方向で取り組み中
  - メタモルフィックテスティング，
    全体精度よりも密な評価，
    再訓練（デバッグ）サイクルなど

[Tian et al., DeepTest: Automated Testing of Deep-Neural-Network-driven Autonomous Cars, 2018]

演繹と帰納の融合

- システム全体をブラックボックステスト，以上？
  - 問題が大きすぎる（例：不具合の原因追及が困難）
- 自動運転や，機械学習工学一般での典型課題

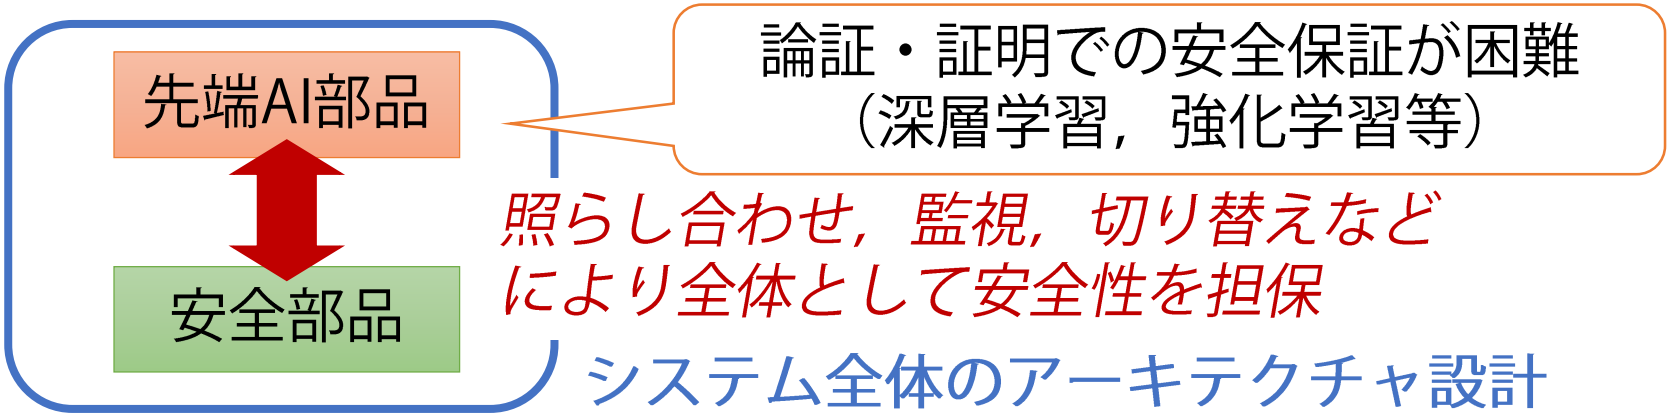

➡ ***形式手法（演繹的保証）による問題分割の力・強い保証の力をテスト（帰納的保証）と組み合わせ***

- 手持ち技術：「証明リファクタリング・再利用」

[T. Kobayashi et al., Consistency-Preserving Refactoring of Refinement Structures in Event-B Models, 2019]

まとめ：AIによるテスト・AIのためのテスト

- 発見的・経験的なアプローチ

  「実行可能なもの」があれば適用できる，

  （一つの）重要で現実的なアプローチ

  - 実世界の難しさとの戦いも主軸に

    （不確実性・オープン性）

  - 理論・演繹と経験・帰納の協働へ

  - 皆様からの問題投げ込みを受けて活発化・技術深化

  ➡ トップダウンの取り組みとツール化へ

今日お話ししなかった
ビッグデータを活用した
AIによるテストの可能性も