

## Anomaly Detection in Smart Home Networks using Situation Estimation in-Home Activities

田中 雅弘

大阪大学 大学院情報科学研究科  
村田研究室

2020/2/12

## ホームIoT 機器における不正操作

### • 深刻な問題に直結

- 生命に危険がおよぶ可能性[1]
  - 例：ヒータの不正操作による火傷/火災
- 電力網への損害の可能性[2]

### • 従来のパターンマッチングによる検知が困難

- 乗っ取ったスマートフォン、スマートスピーカを経由する可能性
  - 正常な操作と同じプロトコルに従って不正操作
- 機器操作に関するデータの数が少ない
  - 統計的手法や深層学習が困難




[1] S. Karmali, E. Pappas, and A. Pappas, "Surge in smart grid and smart home security: threats, challenges and countermeasures," IEEE Communications Surveys & Tutorials, vol. 16, no. 4, pp. 2003–2024, 2014.  
[2] S. Saha, P. Hui, and H. V. Poor, "Blackbox: An insider of high voltage decision design the power grid," 2019 IEEE Security Symposium (IEEE Security Symposium), 2019, pp. 15–12.

## 宅内のユーザの行動パターンに基づく異常検知手法<sup>[3]</sup>

### • 手法

- 機器操作時の状況と行動順序を、行動パターンとして学習
  - 状況：操作が行われた時刻、室温
  - 行動順序：機器の操作やユーザの入退室などが行われる順序
- 各状況の行動パターンと一致しない操作を検知



- 単独で使用される機器の検知精度が低い
  - 行動順序が存在しないため
- 「状況」の定義について詳しく検討が必要
  - 同じ時刻、室温でも操作される確率は異なる
  - 例)コンロが操作される状況
    - 家族が夕飯の準備中：頻繁に使用
    - 家族が全員睡眠中：使用されない

2020/2/12 [3] M. Yamazaki, Y. Ohno, M. Hara, K. Ueda, and Y. Kato, "Anomaly detection for smart home based on user behavior," in 2019 IEEE International Conference on Consumer Electronics (ICCE), ICEE, 2019, pp. 1–6.

## 研究目的と提案手法

### • 研究目的

機器が操作される宅内の状況を判別し、IoT 機器の不正操作の検知精度を向上させる

### • アプローチ

機器操作履歴とセンサデータから宅内の状態の遷移を推定し、機器が操作されやすい状況を学習する


1. 機器操作とセンサデータから状態遷移モデルを定義
2. 遷移確率の各状態の操作確率を計算し学習
3. 機器操作履歴とセンサデータから現在の状態を推定

2020/2/12

## 研究方法 データ収集のためのシステム

### • データ収集のためのシステムを構築

- 各家電に対応したAmazon Dash ボタンを設置
- 家電を使用した際、対応したAmazon Dash ボタンを押す
- Raspberry Pi でボタンを押したタイミングを記録



### • 実際の家庭においてデータを収集

- 上記のシステムを実際の家庭に導入
- IoT センサを設置
  - 室温センサ、湿度センサ、騒音センサ、気圧センサ、CO2センサ
  - プライバシーを考慮

2020/2/12

## 宅内の活動の状態遷移モデル

### • 宅内の活動の状態を定義

- ユーザの状態と機器の状態の組み合わせによって定義
  - ユーザの状態
    - センサデータから推定される宅内のユーザの状態
    - 取得できるセンサデータの種類、精度から決定
    - 例) 「活動中」「睡眠中」「外出中」
  - 機器の状態
    - 不正操作検出の対象である機器の状態
    - 「使用中」「 $T_x$ 分以内に使用」「使用後 $T_y$ 分以内」「その他」の4状態

### • 遷移確率と各状態での機器操作確率によりモデル化

- 活動中 × 使用中
- 活動中 ×  $T_x$ 分以内に使用
- 活動中 × ...
- 外出中 × ...
- ...
- 睡眠中 × 使用後 $T_y$ 分以内
- 睡眠中 × その他



2020/2/12

## 現在の宅内の状態推定と不正操作検知

### 1. 初期化

- 開始時はどの状態であるか不明
- 全ての状態が同じ確率になるよう初期化
- $\alpha_0(i) = \frac{1}{c}$   $c$ : 状態数  
 $\alpha_t(i)$ : 時刻 $t$ における状態 $i$ である確率

### 2. 状態遷移

- 学習した状態遷移確率を掛け合わせることで遷移
- $\hat{\alpha}_t(i) = \sum_c \alpha_{t-1}(c) a_{T(t-1)}(c, i)$   $a$ : 状態遷移確率

### 3. 観測値による補正

- 観測された機器操作、センサデータを使用
- ベイズ推定を行うことにより補正
- $P(x_t | S_t = i) = \prod_n \beta(x)(x_t, i, n)$   $\beta(x)(x_t, i, n) = \begin{cases} b(i, n) & n \in x_t \\ 1 & n \notin x_t \end{cases}$
- $\alpha_t(i) = \frac{P(x_t | S_t = i) \hat{\alpha}_t(i)}{\sum_j P(x_t | S_t = j) \hat{\alpha}_t(j)}$   $b$ : 機器操作確率

### 4. 検知

- 現在の状態確率を用いて不正操作を検知

2020/2/12

6

## 評価方法

- 比較対象: 時間帯のみを利用した手法

- 検知対象: コンロ

- 実際の家庭で頻繁に使用
- 火災などの深刻な問題

- 評価方法

- 1家庭の4か月間 (2018年12月 ~ 2019年3月)
- テストデータに毎分不正操作を混入
- LOO-CV (Leave-One-Out Cross-Validation)
  - 学習データ: 特定の1日分を除くデータ
  - テストデータ: 特定の1日分
  - 各日の結果を合算し検知率、誤検知率を算出

- 評価指標

- 検知率 =  $\frac{\text{検知した不正操作数}}{\text{混入した不正操作の総数}}$
- 誤検知率 =  $\frac{\text{誤検知した正常操作数}}{\text{正常操作の総数}}$

パラメータの設定


$T_x$	30
$T_y$	30
$T_z$	30

2020/2/12

7

## 評価結果

- 誤検知率 20.1% で、検知率72.3%
- 時刻のみを用いた状況定義手法よりもAUCにおいて改善



比較手法と提案手法のROC曲線

2020/2/12

8

## まとめと今後の課題

- 本研究のまとめ

- 実家庭においてデータ収集
- 宅内の行動の推定を用いた手法を提案
  - 機器操作とセンサデータから宅内の行動を状態遷移モデルで定義
  - 遷移確率と各状態の操作確率を計算することで学習
  - 学習された確率と、現在の観測値から現在の宅内の状態を推定
  - 推定された宅内の状態から不正操作の検知
- 実際の家庭から得られたデータを用いた評価
  - 既存手法のうち、状況情報 (時刻) のみを利用した手法よりも改善

- 今後の課題

- 操作パターンを用いた手法とかけ合わせた場合の評価
- 他の機器での評価
  - ヒータ、エアコン、照明、扇風機、洗濯機、TV

2020/2/12

9