



[1]



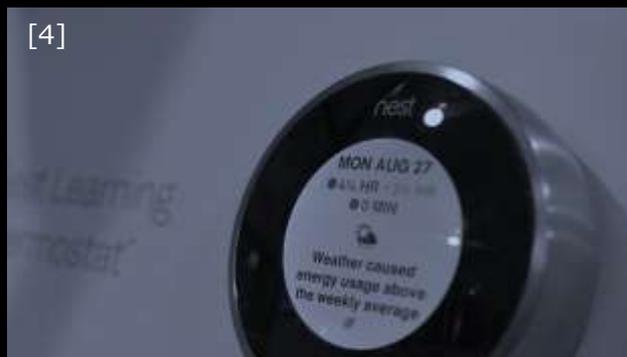
[2]



[3]

# オンデバイス学習：教師データ無しで置くだけ異常検知

慶應義塾大学 理工学部 情報工学科  
准教授 松谷宏紀



[4]



[5]



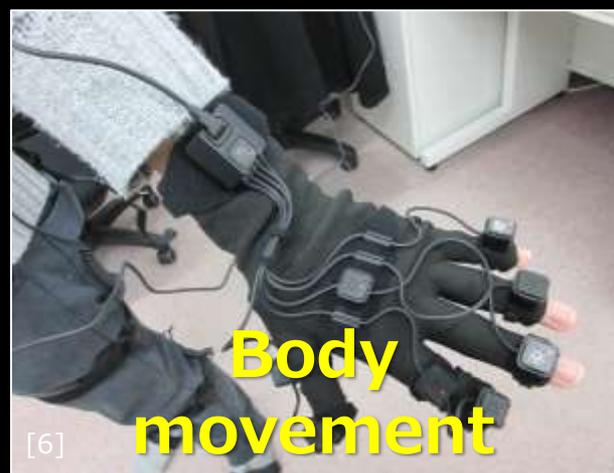
[6]

2019年9月20日

[1] KUKA Roboter GmbH, Bachmann (Public Domain) [2] <http://www.fatcow.com/data-center-photos> [3] Josh Sorenson (Public Domain)  
[4] Raysonho @ Open Grid Scheduler / Grid Engine (Public Domain) [5] Sanderflight at Dutch Wikipedia (Public Domain)

# IoT機器のアプリケーション

- 工場、サーバラック、ロボット、家庭、監視、ヘルスケア



# IoT機器による異常検知

- 工場、サーバラック、ロボット、家庭、監視、ヘルスケア

[1]

## 異常検知

- ✓ 「通常」として定義された振る舞いに合致しないパターンを見つけること
- ✓ 異常 = レアとは限らない

[2]

[3]

## IoT機器による異常検知

- ✓ 大半のセンサデータをIoT機器内で処理
- ✓ 低コスト：通信費やクラウド利用料がかからない
- ✓ 省エネ：無線通信の電力はムーアの法則が効かない

[4]

[5]

[6]

# 実世界にAIを導入する際の課題

- 工場、サーバラック、ロボット、家庭、監視、ヘルスケア

[1]

## 画像認識 vs. 実世界異常検知

- ✓ 画像認識 → 「猫の画像」は世界中どこでも猫！
- ✓ 実世界異常検知 → 環境ごとに「正常」が全く違う

環境（周囲の振動、騒音、水蒸気、明るさ）は変動

- ✓ センサの位置、周囲の装置の稼働状況、...

ラベル付き教師データの準備は大変

- ✓ パターン数が多く、正確なラベル付けが難しい

課題：環境や状況の変化に応じてセンサ1つ1つ

学習し直すのか？教師データの準備が大変！

[4]

[5]

[3]

# 従来技術の課題と解決策

環境や状態の変化に応じてセンサ1つ1つ学習し直すのか？  
教師データの準備が大変！

## 我々のアプローチ

オンライン逐次学習

+

教師なし異常検知

事前のオフライン学習なし  
置かれたその場で学習

ラベル付き教師  
データは不要

ノイズを含む  
正常パターン

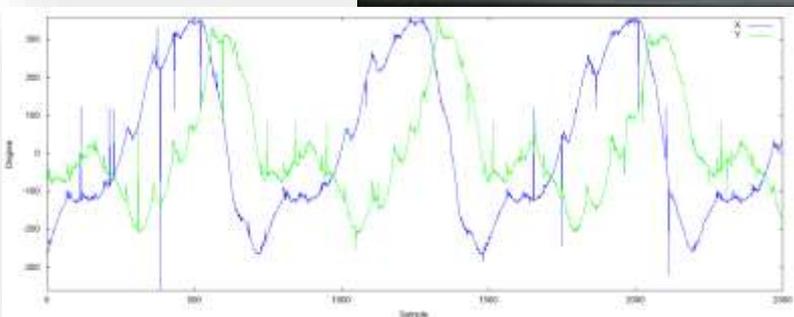
## 使い方

- ① 異常検知装置を設置
- ② 「正常パターン」をその場で覚えさせる
- ③ 普段と違うパターンが来たら「異常」と判定



# 従来技術の課題と解決策

環境や状態の変化に応じてセンサ 1 つ 1 つ学習し直すのか？  
教師データの準備が大変！



## 使い方

- ① 異常検知装置を設置
- ② 「正常パターン」をその場で覚えさせる
- ③ 普段と違うパターンが来たら「異常」と判定

- ① テントウムシの方位センサをオン
- ② 何週か回って覚えさせる
- ③ 障害物 → 異常と判定



# 新技術：オンデバイス学習

深層学習など：  
事前に学習しておく

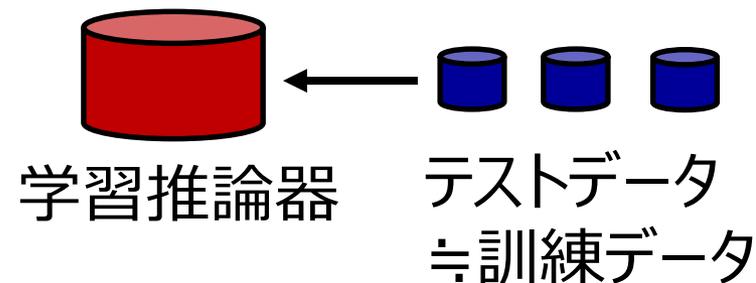
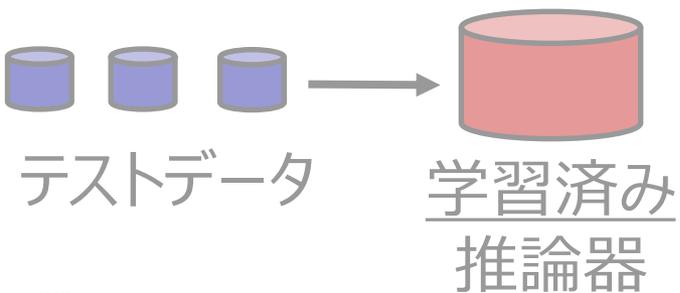
我々のアプローチ：  
その場で「正常」を学習

オフライン学習

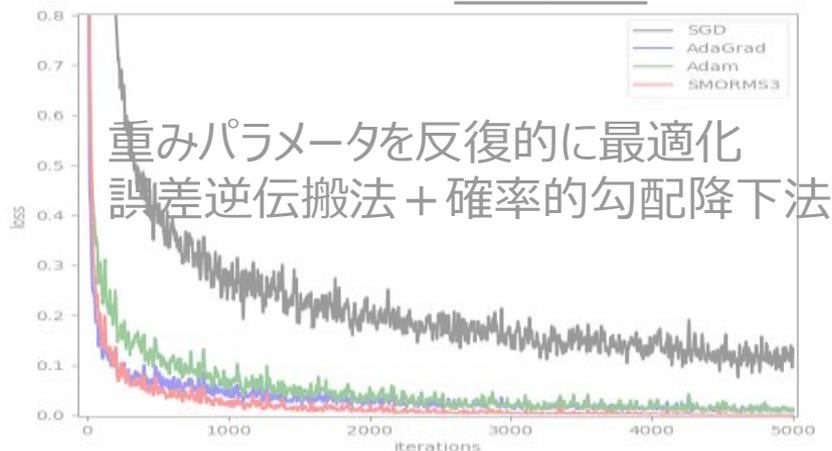
オンライン学習

推論のみ

逐次学習 + 推論



オンデバイス学習（来たデータをその場で学習  
→ 環境変化に適応できる）

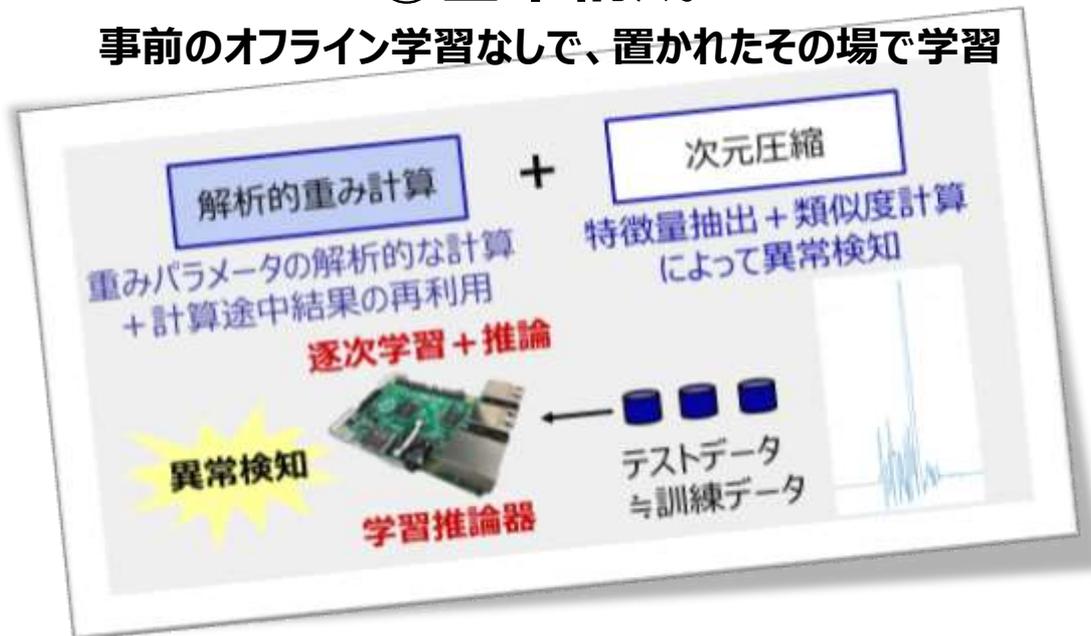


組み込みシステム（低コスト） 7

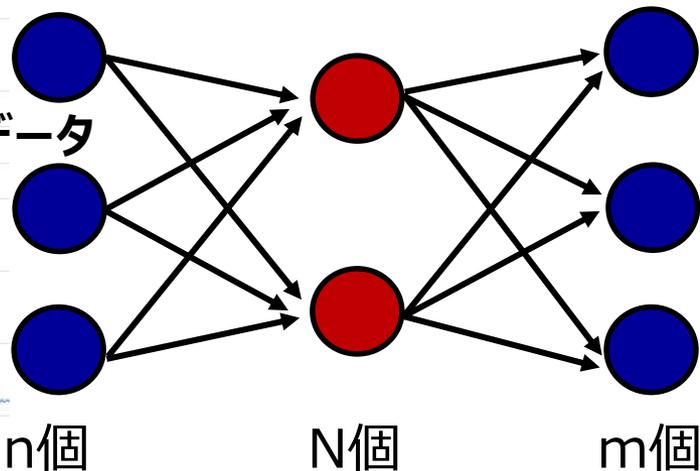
# オンデバイス学習：基本構成

## ① 基本構成

事前のオフライン学習なしで、置かれたその場で学習



入力例：  
1024次元データ



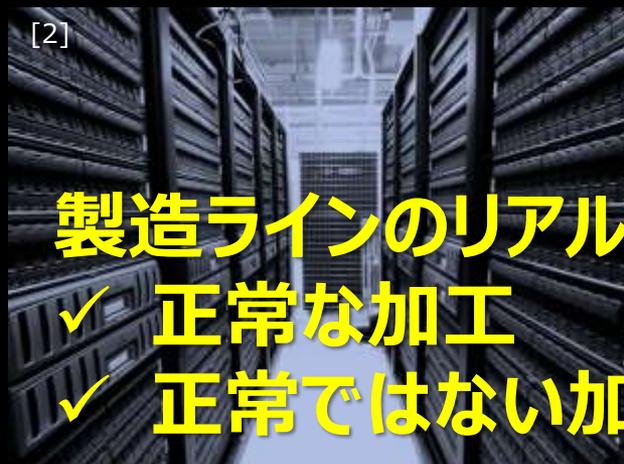
データ  $i$  を学習したときの途中結果  
を使って、データ  $i+1$  を学習



**特長：これを低コストで実現**

# 応用例 1 : 工場の製造ライン

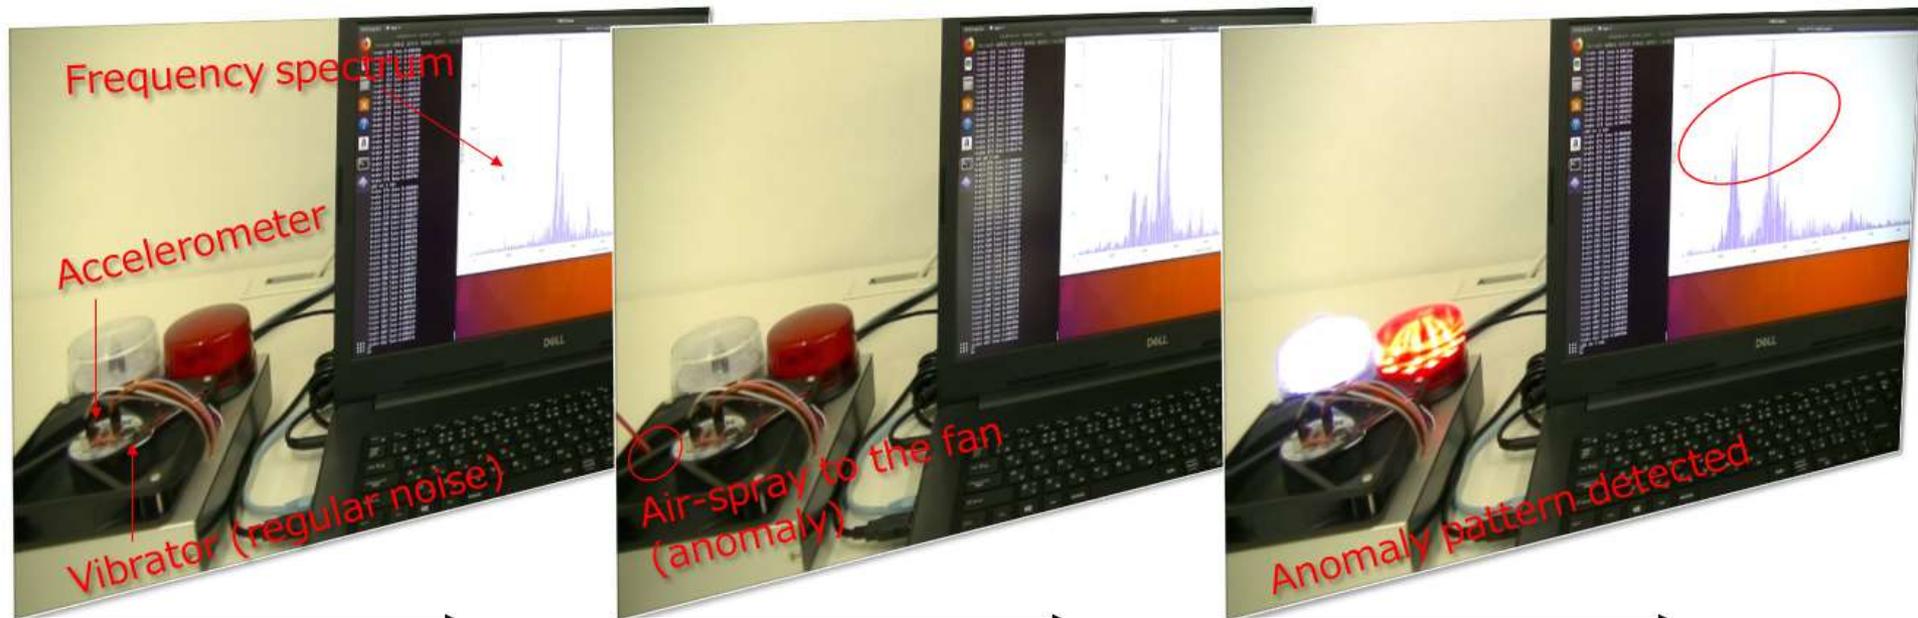
- 製造ラインのリアルタイム品質管理



# 応用例 1 : 工場の製造ライン

回転機械の振動を学習 → 普段と違うパターンを検出

※デモ用の異常としてエアスプレー（画面左の赤い管）を使用



**Step 1:**  
Normal pattern  
including regular  
noise is learned

**Step 2:**  
Air-spray is blew to  
the fan

**Step 3:**  
Anomaly pattern  
(air-spray) is detected

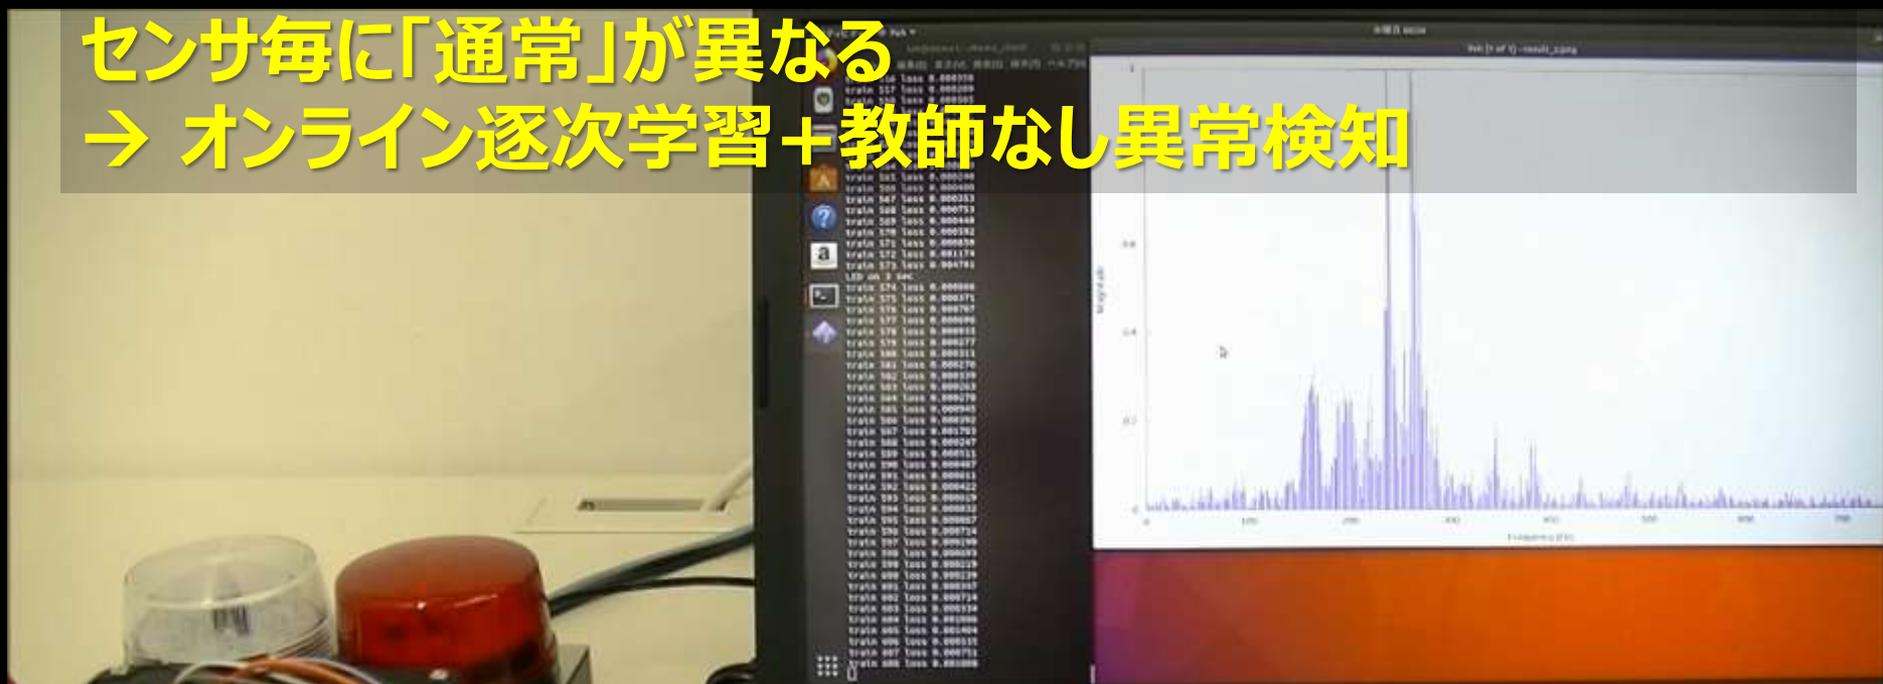
ノイズ（エアスプレー）を含めてその場で学習し、異常検知

# 応用例 1 : 工場の製造ライン

回転機械の振動を学習 → 普段と違うパターンを検出

※デモ用の異常としてエアスプレー（画面左の赤い管）を使用

センサ毎に「通常」が異なる  
→ オンライン逐次学習 + 教師なし異常検知



事前のオフライン学習なしで、データを流しながら置かれた環境に適応し、普段と異なるパターンが来たら異常  
→ 導入容易性・管理容易性◎

# オンデバイス学習：新技術の概要

深層学習など：  
事前に学習しておく

我々のアプローチ：  
その場で「正常」を学習



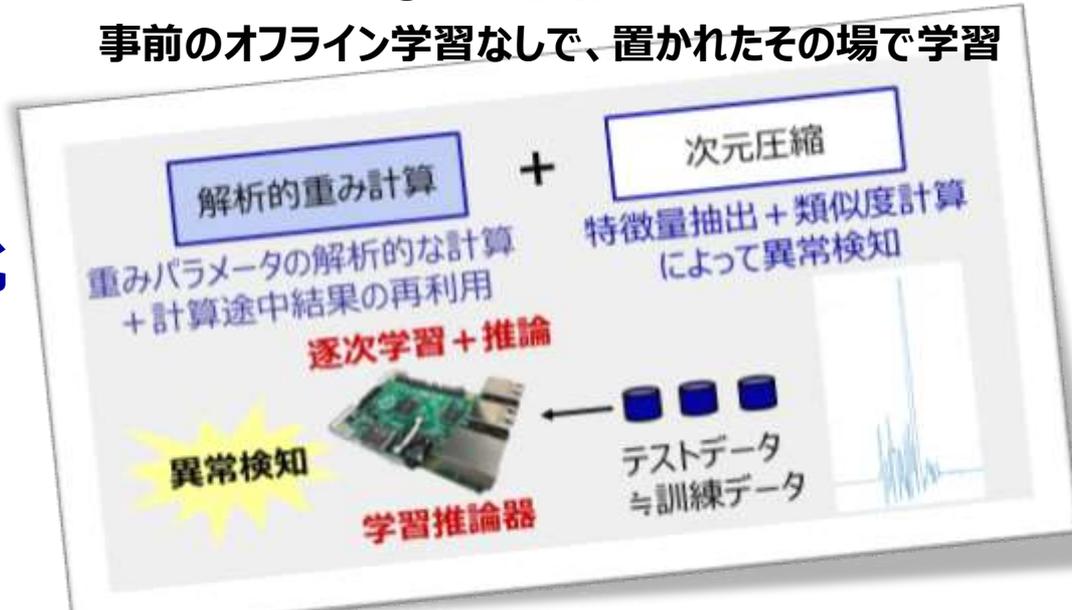
コア技術 1：疑似逆行列計算の簡易計算化 → 低コスト実装

コア技術 2：(1) の周辺技術 (複数定常点、忘却、安定性)

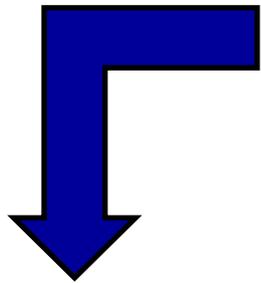
コア技術 3：(1) + (2) を環境センサチップとして実現予定

## ① 基本構成

事前のオフライン学習なしで、置かれたその場で学習

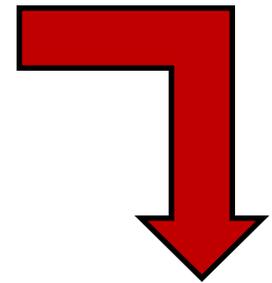


## ② 低コスト化

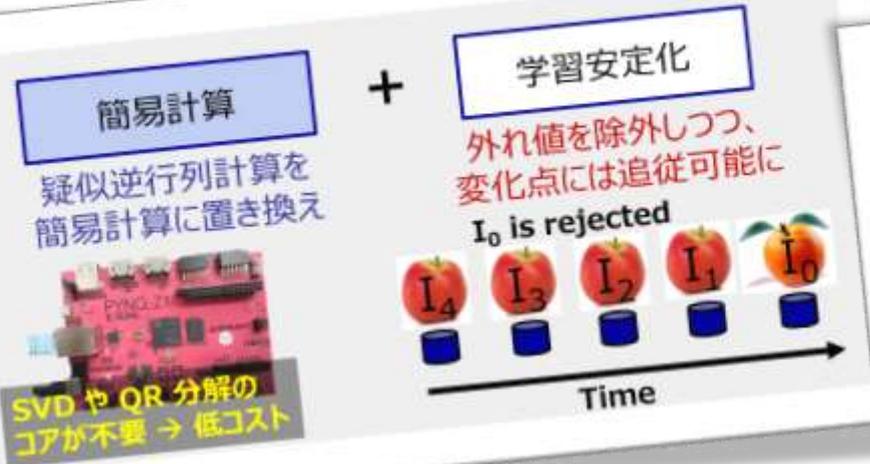


計算が軽いので、エッジデバイスに埋め込み可能

## ③ 高精度化

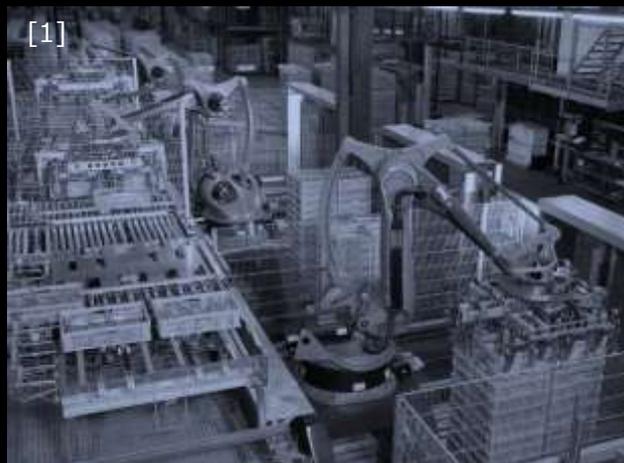


複雑な入力パターンに対する高精度化、高機能化



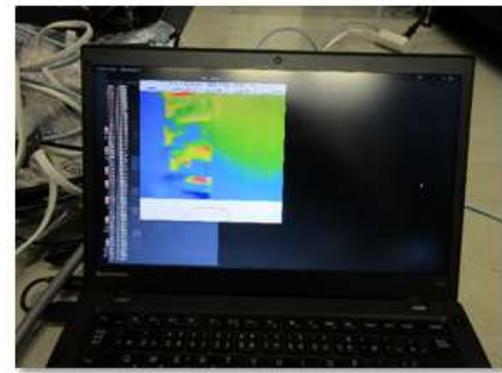
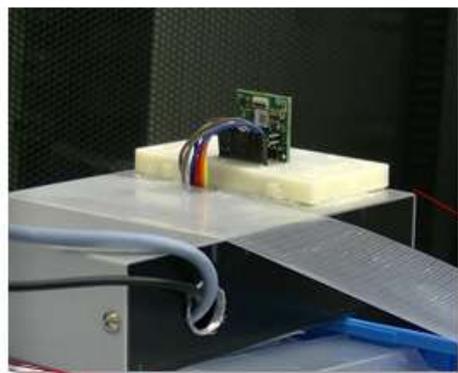
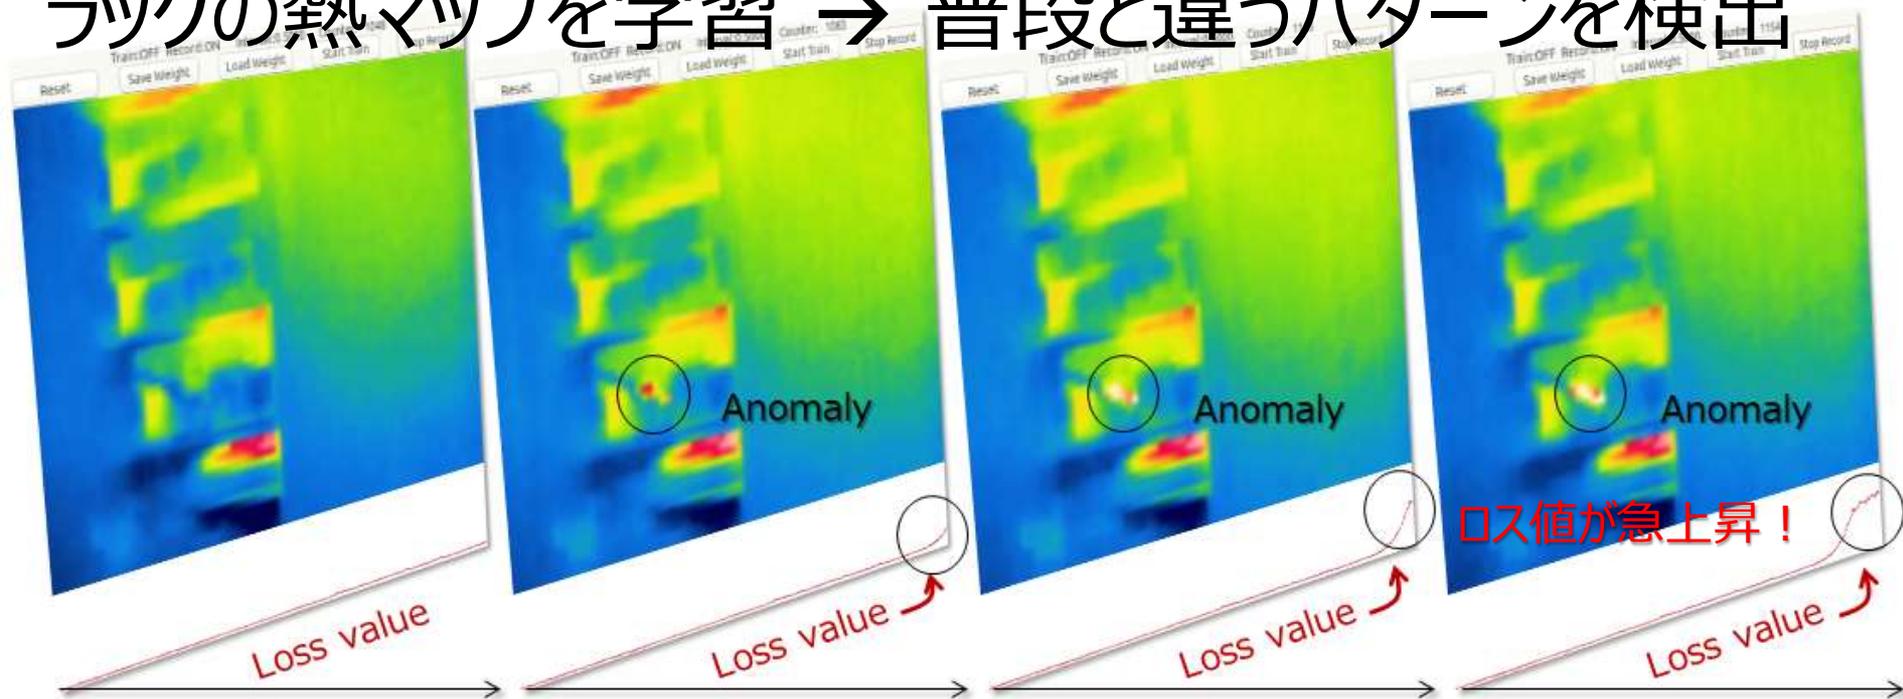
# 応用例 2 : サーバラックや計算機

- サーバラックや計算機の異常発熱を検出



# 応用例 2 : サーバラックや計算機

ラックの熱マップを学習 → 普段と違うパターンを検出



On-device learning camera

Remote monitoring 15

# 応用例 2 : サーバラックや計算機

ラックの熱マップを学習 → 普段と違うパターンを検出

※デモ用の異常（熱源）として半田ごてを使用

サーバラック毎に「通常」が異なる  
→ オンライン逐次学習＋教師なし異常検知

事前のオフライン学習なしで、データを流しながら置かれた環境に適応し、普段と異なるパターンが来たら異常

# 応用例 3 : ドローンのプロペラ

- ドローンの状態は、ペイロードや風向き等に左右される

[1]

[2]

[3]

Robot (UAV)

ドローンの墜落は大事故を引き起こす

✓ プロペラは破損・変形しやすい

✓ 破損・変形したプロペラの使用は危険

プロペラの異常検知

✓ 正常な振動パターン

✓ 普段と違う振動パターン

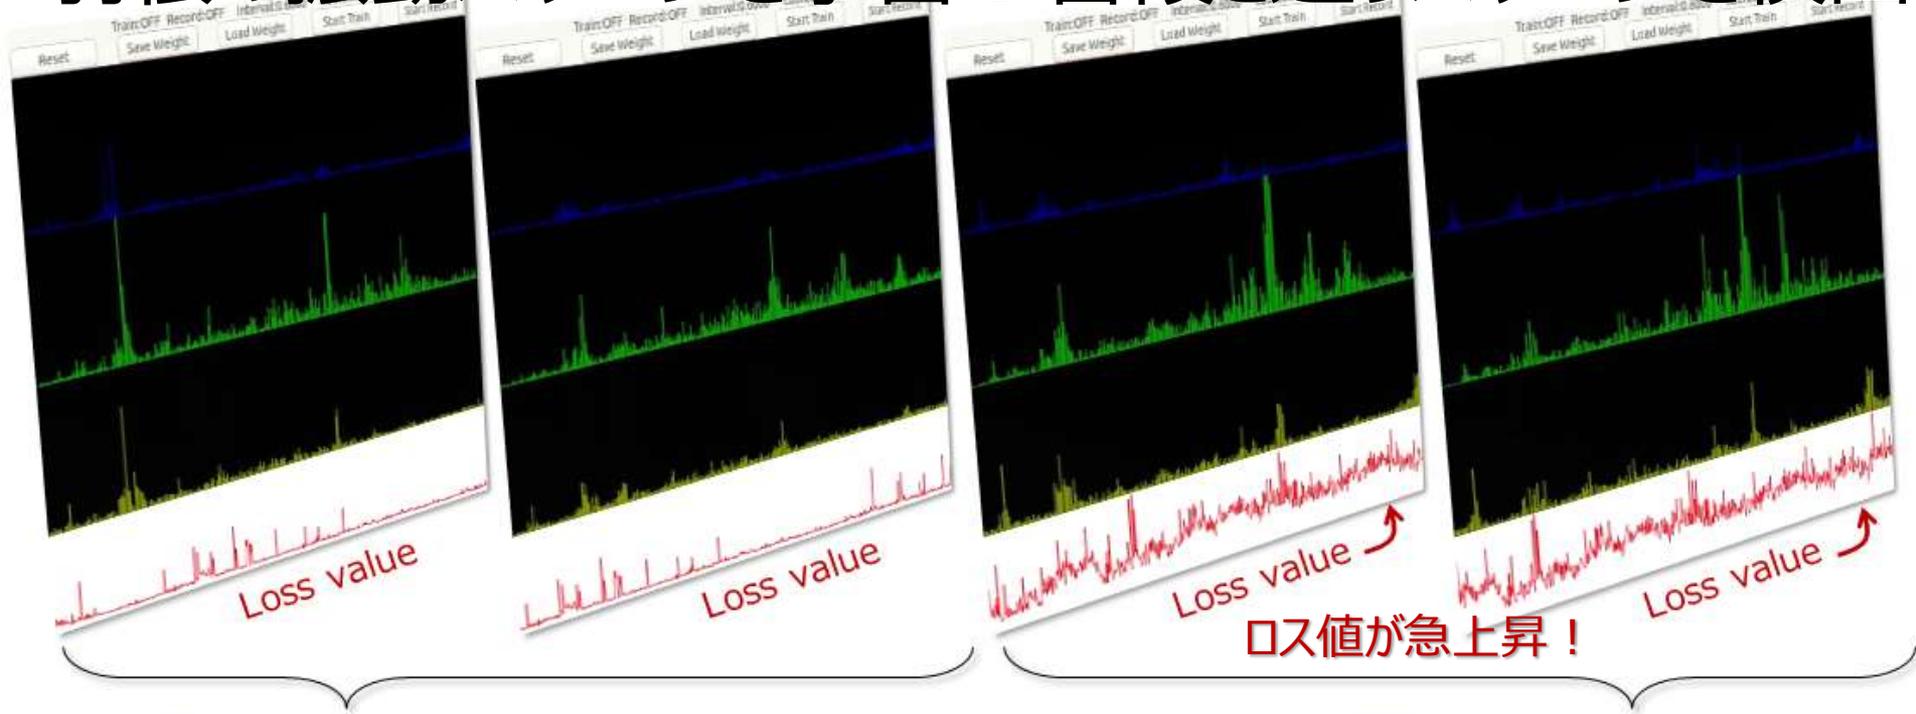
[4]

[5]

[6]

# 応用例 3 : ドローンのプロペラ

羽根の振動パターンを学習 → 普段と違うパターンを検出



# 応用例 3 : ドローンのプロペラ

羽根の振動パターンを学習 → 普段と違うパターンを検出

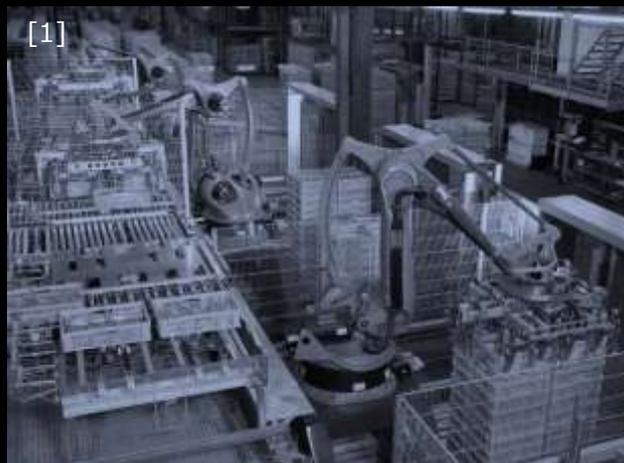
※デモ用の異常として損傷したプロペラ（赤）を使用

ドローンの状態は、荷物の重さや環境によって変化  
→ オンライン逐次学習 + 教師無し異常検知

バッテリー駆動 + 小型・軽量なのでドローンに搭載可能

# 応用例 4 : 家庭やオフィス環境

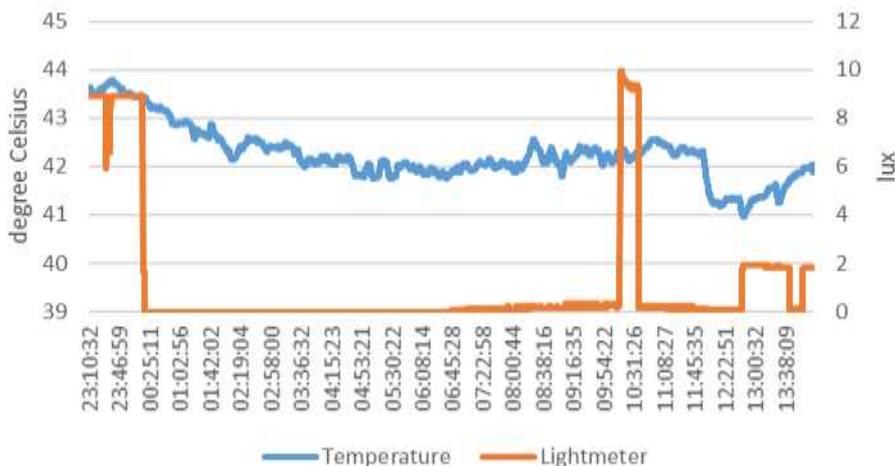
- 家庭やオフィスでのBLEタグを用いた異常検知



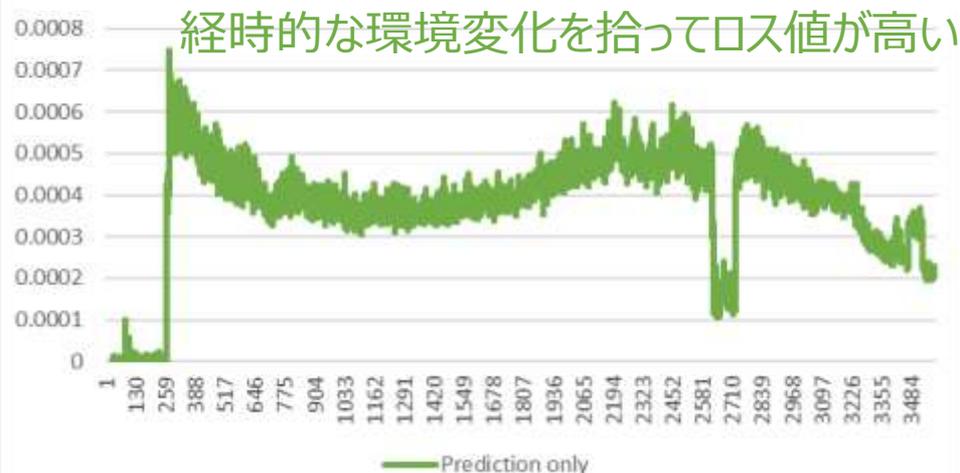
# 応用例 4 : 家庭やオフィス環境

## 推論のみ vs. 提案手法 (推論 + 逐次学習 + 忘却)

センサデータ ( — 温度 — 照度)



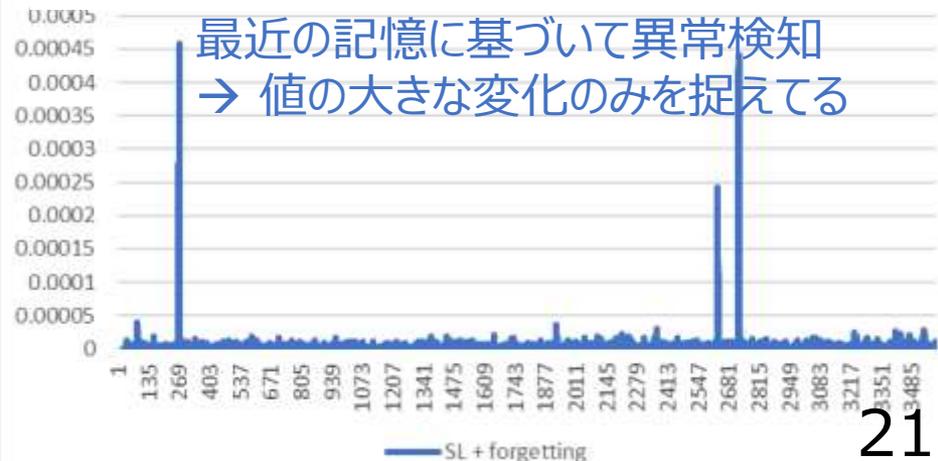
ロス値 (開始 6 分間学習し、後は推論のみ)



### BLEタグを研究室に設置 :

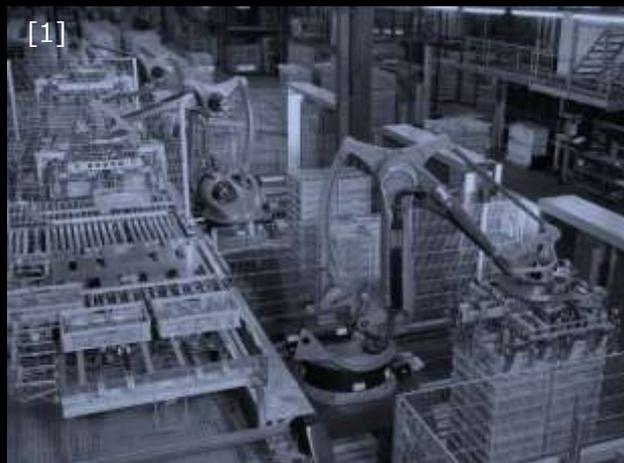
温度、湿度、照度、バッテリー残量、3軸加速度、3軸地磁気、3軸角速度などを測定

ロス値 (提案手法 : 推論 + 逐次学習 + 忘却)



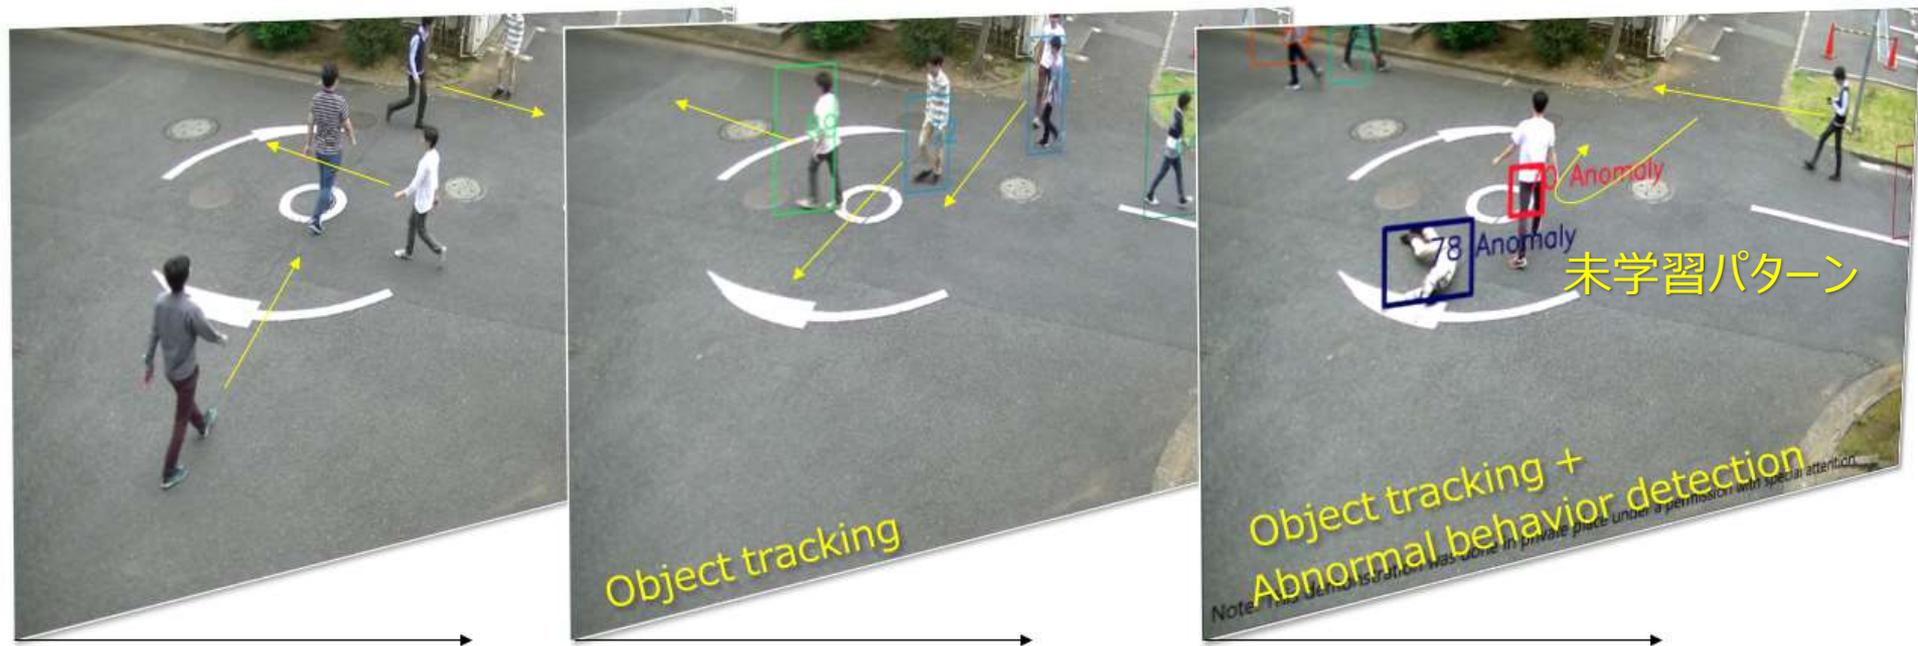
# 応用例 5 : 監視カメラ映像

- オンデバイス学習を監視カメラの異常行動検出に応用



# 応用例 5 : 監視カメラ映像

一般的な通行パターンは、監視カメラの位置やアングルによって異なる → 自律的に「通常」を学習するカメラ



Note: This demonstration was done in private place under a permission with special attention

# 応用例 5 : 監視カメラ映像

一般的な通行パターンは、監視カメラの位置やアングルによって異なる → 自律的に「通常」を学習するカメラ



普段と違う動きの歩行者を検出すると「Anomaly」と表示

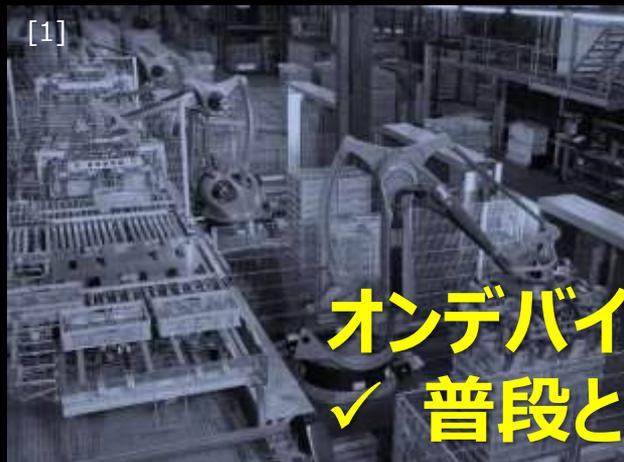
Note: This demonstration was done in private place under a permission with special attention.

Resolution of this video is reduced intentionally.

# 応用例 6 : 人の異常検知

普段との動きの違い : 怪我、疲労、パフォーマンス低下

[1]



[2]

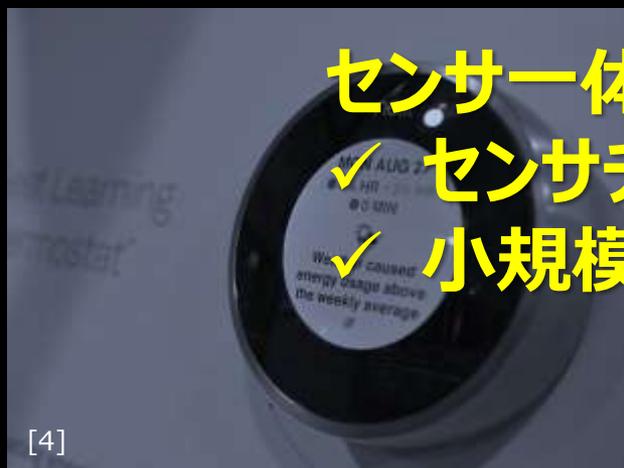


[3]

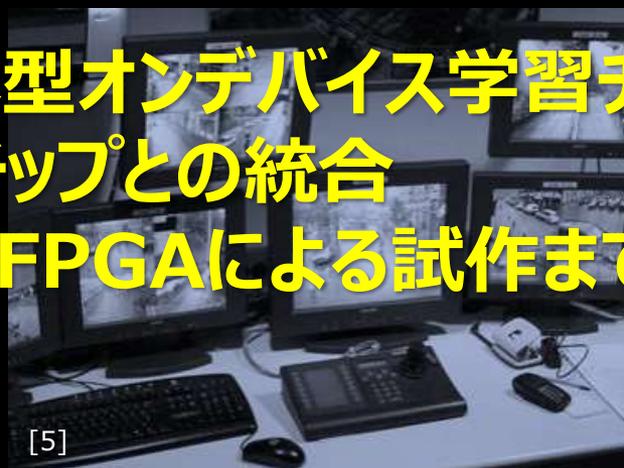


オンデバイス学習チップを人体に装着  
✓ 普段と違う動きを検出

[4]



[5]



[6]

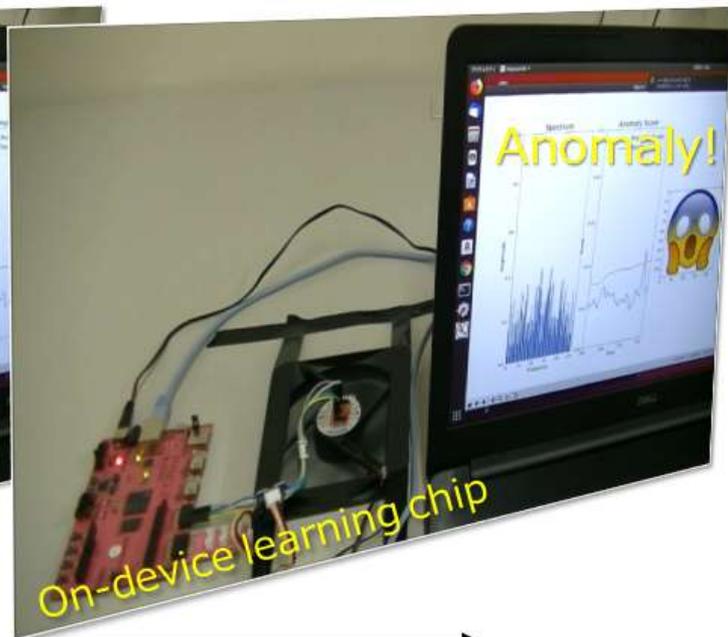
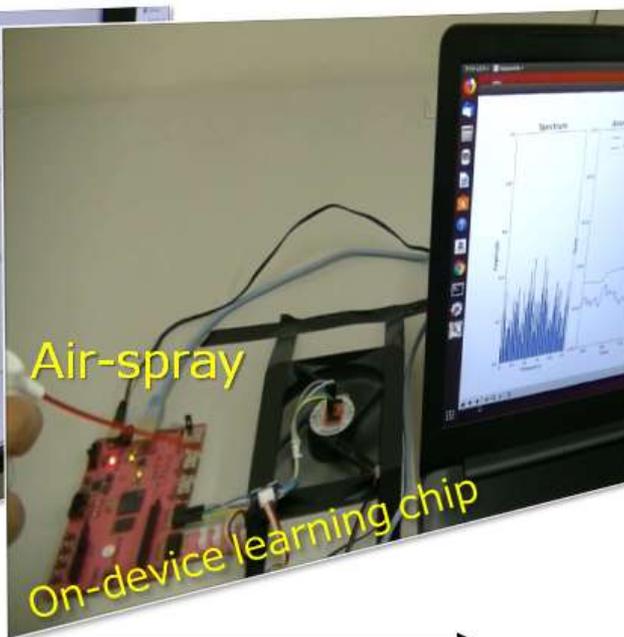


センサー体型オンデバイス学習チップ  
✓ センサチップとの統合  
✓ 小規模FPGAによる試作まで実施

Body  
movement

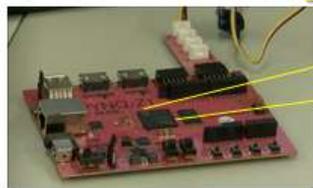
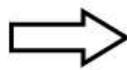
# 応用例 6 : 人の異常検知

センサー一体型オンデバイス学習チップを人体に装着  
→ チップ開発の前段階として小規模FPGAによる試作まで実施



**Price \$6,426**  
[Tsukada, EuroPar'18 WS]

Our latest design

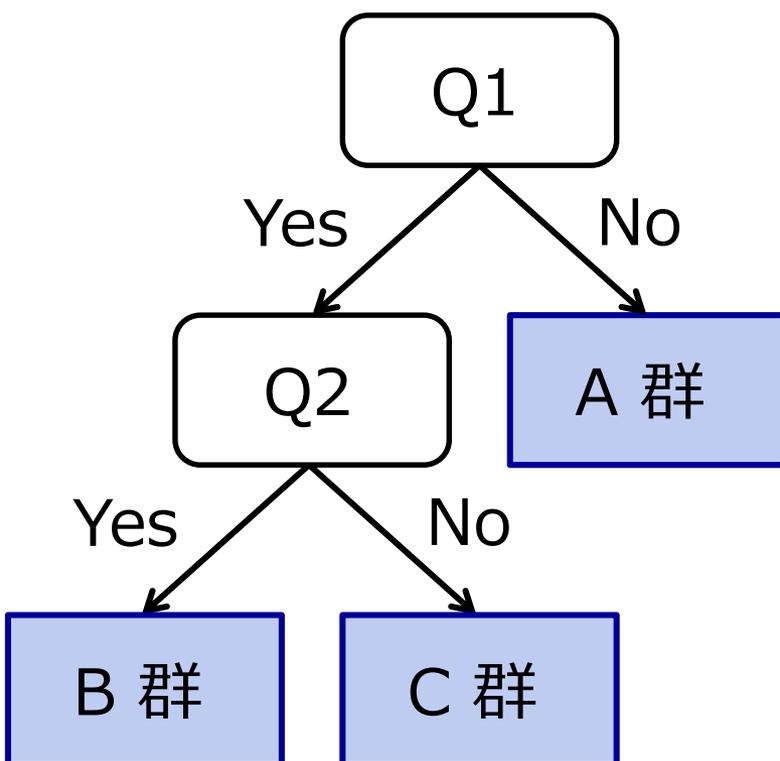


**Price \$114**  
[Tsukada, FCCM'19 Demo]



# 本提案と従来技術との比較

## OSL-UAD = オンライン逐次学習 による教師なし異常検知



Q1 : 次元数は多いか ?

(Yesなら高次元、Noなら低次元)

- 周波数スペクトル → **Yes**
- 高次元時系列データ → **Yes**
- 画像 → **Yes**

Q2 : 教師データを事前準備できるか ?

(Yesならオフライン学習、Noはオンライン学習)

- 正常パターンが変動 → **No**
- 環境・ノイズが変動 → **No**
- 正常パターンが多すぎる → **No**

A 群 : AR、LOF、k-NN、iForest、...

B 群 : DNN、CNN、RNN、...

C 群 : **本研究 (OSL-UAD)**

※教師データの準備が苦にならず、環境や状態も変わらないなら、まずは深層学習です。一方、製造現場では教師データの準備がAI導入の最大の課題とも言われていて、この点の解決を目指しているのが本研究です。

# 企業様への期待：普及と実用化

- ライセンスのご利用、社会的に重要な用途への応用

|       |  |
|-------|--|
| 発明の名称 | データ処理装置、データ処理システム及びプログラム<br>(特願2018-125151の国内優先) |
| 出願番号  | 特願2018-227556                                    |
| 出願人   | 慶應義塾大学、東京大学                                      |
| 発明者   | 松谷 宏紀、塚田 峰登、近藤 正章                                |

# 企業様への期待：普及と実用化

- ライセンスのご利用、社会的に重要な用途への応用
- お試し利用：ソフトウェア開発キット

|                               |                         |
|-------------------------------|-------------------------|
| <b>OSUAD_Predict()</b>        | 推論を実行し、ロス値を取得。          |
| <b>OSUAD_Train()</b>          | 逐次学習を実行。ついでに推論も実行している。  |
| <b>OSUAD_Delayed_Train()</b>  | 逐次学習を実行。自動的に外れ値を除外。     |
| <b>OSUAD_Reset()</b>          | 推論器のリセット。               |
| <b>OSUAD_Save()</b>           | 現在の推論器を保存。              |
| <b>OSUAD_Load()</b>           | 保存した推論器を読み込む。           |
| <b>OSUAD_Set_Threshold()</b>  | 外れ値除外ためのスレッシュホールド（絶対値）。 |
| <b>OSUAD_Set_Outlier()</b>    | 外れ値除外ためのスレッシュホールド（相対値）。 |
| <b>OSUAD_Set_Forget()</b>     | 過去の記憶を忘れるための忘却係数。       |
| <b>OSUAD_Set_Capacity()</b>   | 想定する正常パターンの数（クラスタ数）を指定。 |
| <b>OSUAD_Get_Confidence()</b> | 状態推定。どの正常パターンクラスタに属するか？ |
| <b>OSUAD_Reinitialize()</b>   | 正常パターンクラスタを動的に再構成。      |

# 企業様への期待：普及と実用化

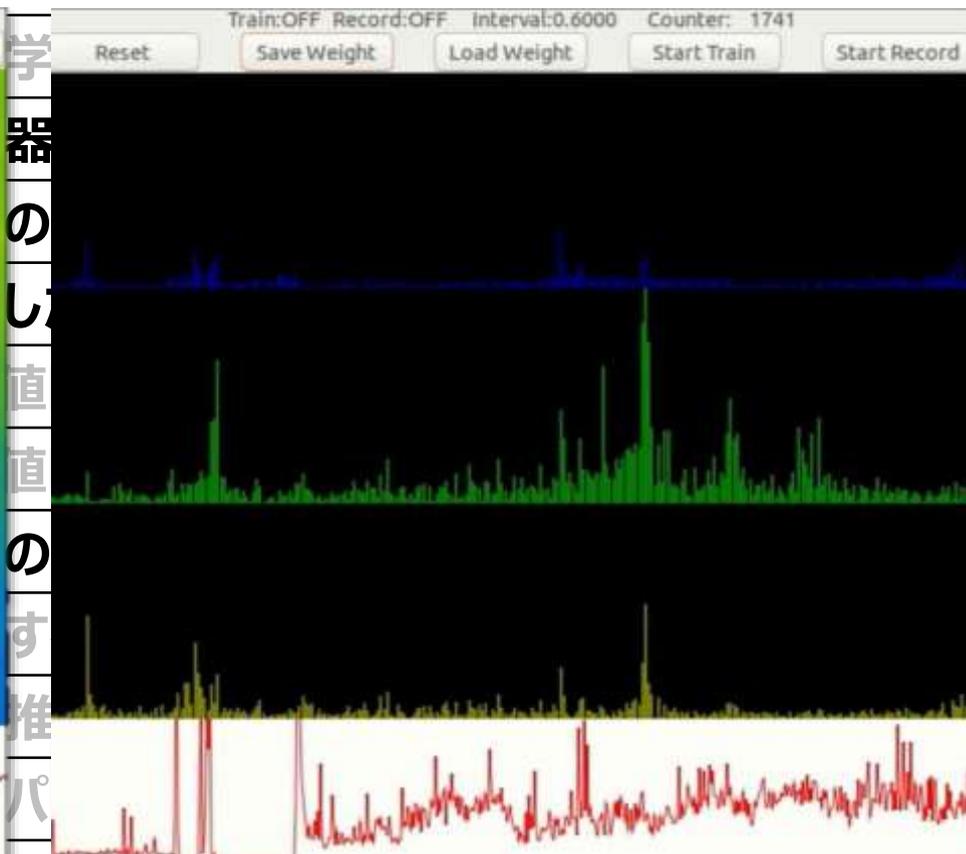
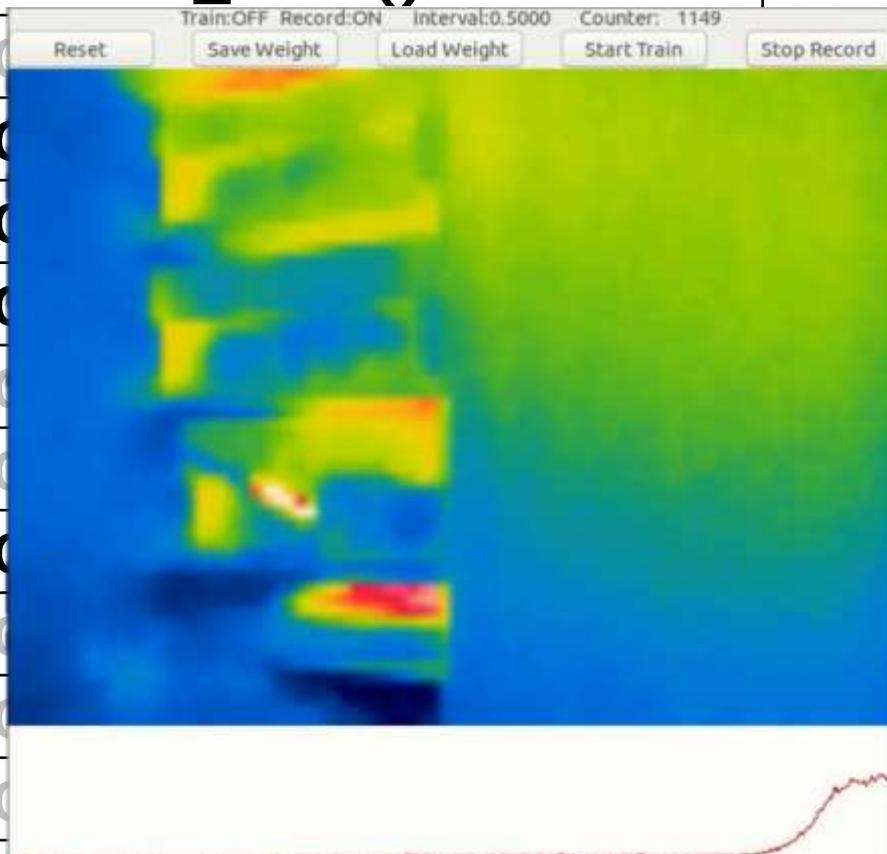
- ライセンスのご利用、社会的に重要な用途への応用
- お試し利用：ソフトウェア開発キット

OSUAD\_Predict()

推論を実行し、ロス値を取得。

OSUAD\_Train()

逐次学習を実行。ついでに推論も実行している。



# まとめ：オンデバイス学習の提案

環境や状態の変化に応じてセンサ1つ1つ学習し直すのか？  
教師データの準備が大変！ ⇨ オンデバイス学習

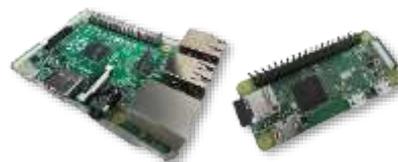
提案アルゴリズムを様々なプラットフォームに展開



高性能  
(GPU/FPGA)



産業用PC



IoT機器



小規模FPGA  
(チップ化予定)

**企業様への期待：ライセンスのご利用、社会的な重要な用途への応用**

## お問い合わせ先：

学校法人慶應義塾 学術研究支援部 知的資産担当

阿部 仁

hitoshi.abe@adst.keio.ac.jp

0466-49-3436

- On-device learning anomaly detection
  - Mineto Tsukada, et al., "A Neural Network Based On-Device Learning Anomaly Detector for Edge Devices", arXiv:1907.10147 (2019).
  - Mineto Tsukada, et al., "An FPGA-based On-device Sequential Learning Approach for Unsupervised Anomaly Detection", FCCM 2019 Demo Night.
  - Mineto Tsukada, et al., "OS-ELM-FPGA: An FPGA-Based Online Sequential Unsupervised Anomaly Detector", Euro-Par Workshops 2018.

- On-device learning core
  - Tomoya Itsubo, et al., "Performance and Cost Evaluations of Online Sequential Learning and Unsupervised Anomaly Detection Core", IEEE COOL Chips 2019.
- Abnormal behavior detection
  - Rei Ito, et al., "An Adaptive Abnormal Behavior Detection using Online Sequential Learning", IEEE EUC 2019.