





置かれた環境で学習する 無線センサ型異常検知システム

松谷 宏紀（慶應義塾大学 理工学部）



IoT : アプリケーション



- エッジAI : エッジデバイス上で動作するAI (用途 : 異常検知など)
工場、設備監視、ドローン、電動車いす、家電、監視カメラ、環境モニタ、...



エッジAI：設備監視の例

・無線センサノードによる空調システムの監視 [1]

エッジ側でセンシング、前処理、推論、学習、異常検知結果の送信




[1] 塚田 峰登, "回転機械の異常振動を検出する無線デバイスの開発", Keio Techno-Mall 2021.

[2] 日刊工業新聞, "環境変化を自動学習 工場装置異常検知 慶大など、AI開発", 2021年12月8日 1面.


エッジAI：設備監視の例

- 貼り付けるだけ異常検知器 [1]

Raspberry Pi Pico、各種センサ、無線モジュール、電池、マグネット
エッジ側でセンシング、前処理、推論、学習、異常検知結果の送信




エッジAI：分類



Six-level rating for edge intelligence [1]

提案：オンデバイス学習
IoTデバイス上で学習と推論


通常は、エッジで推論
(サーバで学習)



[1] Z. Zhou et al., "Edge Intelligence: Paving the Last Mile of Artificial Intelligence With Edge Computing", Proceedings of the IEEE (2019).

オンデバイス学習：必要性

- エッジAIの難しさ：訓練データ（training function）と現場環境（testing function）の乖離が大きくなりがち



エッジAIの一般的な利用手順

1. 訓練データの収集（どこか）
2. サーバ上で学習
3. 現場で推論


1～3が違う場所、違うタイミングで行われるのでズレやすい

一般的な解決策

- ✓ 差異を吸収できる高度な汎化性能
- ✓ 深層ニューラルネットワーク

オンデバイス学習：必要性

- エッジAIの難しさ：訓練データ（training function）と現場環境（testing function）の乖離が大きくなりがち



一般的な解決策

- ✓ 差異を吸収できる高度な汎化性能
- ✓ 深層ニューラルネットワーク

オンデバイス学習 [1]


- ✓ 極小ニューラルネットワーク
- ✓ 現場で学習することで差異や変化に追従

オンデバイス学習：2つのモード

1. 学習モード

2. 推論モード

課題：学習モードと推論モードはいつどのように切り替える？




オンデバイス学習：2つのアプローチ

1. 現場で工夫できるAI

現場のユーザが現場の判断で
追加学習

学習ボタンによる
追加学習



2. 現場に適応できるAI

パターンの変化を自動で検知して
追加学習



検知アルゴリズムによる
追加学習

1-2mW

20-30mW

0.2-1W



2-10W

200W+



オンデバイス学習：各種プロトタイプ

(As of Oct 2022)



AIチップ
(ローム社)

\$5

\$10






\$50

\$500+

FFT

画像処理

物体追跡



LiDAR

加速度センサ


熱カメラ

深度カメラ


RGBカメラ

オンデバイス学習：貼り付けるだけ異常検知器


[x2] See the thermal results (blue and purple).



On-Device Learning of Neural Networks on Wireless Sensor Nodes




On-Device Learning Modules (Left: Accelerometer, Right: Thermal Camera)



オンデバイス学習：アルゴリズム

- ニューラルネットワークの逐次学習アルゴリズム [1] を簡略化
- 正常パターンが複数あっても異常検知可能

例：回転機械の異常検知（複数の回転速度、複数の動作モード、…）




オンデバイス学習：実行時間

• Raspberry Pi Pico (4ドル)、ワイヤレス通信モジュール




1. Sense 2. FFT 3. Predict x4 4. Seqtrain 5. Comm 6. Sleep

(a) Execution time of on-device learning (total)




(b) Execution time of on-device learning (predict & train)



(c) Implementation of sensor node


オンデバイス学習：実行時間

- 4 個の 3 層ニューラルネットワーク（次元数：256-32-256）




1. Sense 2. FFT 3. Predict x4 4. Seqtrain 5. Comm 6. Sleep

(a) Execution time of on-device learning (total)



Predict (N=16) Predict (N=32) Predict (N=48)
Seqtrain (N=16) Seqtrain (N=32) Seqtrain (N=48)

(b) Execution time of on-device learning (predict & train)



(c) Implementation of sensor node


オンデバイス学習：通信量削減

- 推論結果だけ送る（データは送らない）→ 通信エネルギー削減




■ 1. Sense ■ 2. FFT ■ 3. Predict x4 ■ 4. Seqtrain ■ 5. Comm □ 6. Sleep

(a) Execution time of on-device learning (total)



(b) Communication size reduction by on-device learning




(c) Implementation of sensor node

オンデバイス学習：ファンの異常検知

- ・ シナリオ：静音環境にて学習後、騒音環境に置かれて異常検知
 - 推論のみAI：騒音環境に適応できない
 - オンデバイス学習：騒音環境に適応できる

オンデバイス学習の利点：訓練データと現場環境の乖離が大きくても使える




（静音環境：オフィス、騒音環境：換気扇の付近）

オンデバイス学習：ファンの異常検知


- シナリオ：静音環境にて学習後、騒音環境に置かれて異常検知

■ 推論のみAI：騒音環境に適応できない


■ オンデバイス学習：騒音環境に適応できる



(a) Dataset measurement



(b) Normal environment (2500rpm, 2000rpm, 1500rpm, 0rpm)



現場環境 = 静音環境の信号にノイズが重畳

(c) Noisy environment (2500rpm, 2000rpm, 1500rpm, 0rpm)


(静音環境：オフィス、騒音環境：換気扇の付近)

オンデバイス学習：精度


- シナリオ：静音環境にて学習後、騒音環境に置かれて異常検知

■ 推論のみAI：騒音環境に適応できない → 精度が大幅に低下 ☹


■ オンデバイス学習：騒音環境に適応できる → 高い精度をキープ 😊



(a) Summary of seven tasks



(b) Result of 2500rpm task



— On-device learning (trained at noisy env) — Prediction only (trained at normal env)

(c) Result of Damage1 task