

戦略的創造研究推進事業 CREST

研究領域「イノベーション創発に資する人工知能  
基盤技術の創出と統合化」

研究課題「オンデバイス学習技術の確立と社会実  
装」

研究終了報告書

研究期間 2020年4月～2023年3月

研究代表者: 松谷宏紀  
(慶應義塾大学理工学部・教授)

## §1 研究実施の概要

### (1) 実施概要

現実空間で動作するエッジ AI 特有の難しさとして、訓練データと実際にデプロイされる現場環境の乖離が挙げられる。学習に使用した訓練データに対応する関数を **training function**、現場環境で実際に期待される関数を **testing function** としたとき、**training function** と **testing function** が重なることが望ましいが、エッジ AI の場合、両者の乖離が大きくなる場合がある。エッジ AI の一般的なユースケースを考えると、1) モデルの学習に使用する訓練データを収集し、2) サーバ上でモデルを学習し、3) 学習済みモデルを現場にデプロイするという手順を踏む。この場合、ステップ 1、2、3 が異なる場所、異なるタイミング、場合によっては異なるユーザによって実施されるため、**training function** と **testing function** にギャップが生じる原因になる。このギャップに対する一般的な解決策は高い汎化性能の活用であり、そのためにエッジ AI においても高度な深層ニューラルネットワーク (DNN) の利用が進んでいる。一方で、計算資源の限られた IoT デバイスにおいては高度な DNN はメモリサイズや計算量の点でコストが大きい。本研究では、センサやコントローラのようなローエンドなエッジデバイスで上述のギャップに対処するためにオンデバイス学習を提案した。具体的には、汎化性能のために高度な DNN を使うのではなく、極小のニューラルネットワークを用いて計算リソースを削ぎ落して、現場環境で学習することで **training function** と **testing function** のギャップや変化に追従する。

このようなオンデバイス学習器の動作モードとして、**train** モードと **predict** モードの 2 つがある。異常検知用途であれば、**train** モードのときに正常データを与えて正常を学習させれば、**predict** モードに移行後、異常検知器として利用できる。この場合、**train** モードと **predict** モードの切り替えのタイミングが重要であり、このために 2 つのアプローチを考えている。1 つ目は、ユーザが明示的に学習ボタンを押すことで追加学習をトリガーさせるアプローチである。異常検知用途であれば、学習ボタンを押している間、オンデバイス学習器に正常パターンを与えることで正常パターンを学習させる。2 つ目は、コンセプトドリフト検知アルゴリズムによって入力パターンの傾向の変化を検出したときに、自律的に追加学習をトリガーさせるアプローチである。この場合、自律的に **training function** と **testing function** のギャップや変化に追従できるという利点がある。

以上を踏まえ、加速フェーズ開始時に本研究のビジョンを次のように定めた。「本研究ではオンデバイス学習アルゴリズム、連合学習、その周辺技術と集積回路化により、低コストかつ多数のモノが自律的で環境変動に強いインテリジェンスを獲得可能とし、数が多くメンテナンスし難いエッジ AI の自律的運用をサポートする。オンデバイス学習技術を様々な分野に応用し、ローエンドエッジ AI としての有用性を実証する。」

このビジョンを達成するために、慶大松谷グループと慶大近藤グループ (旧東大グループ) はオンデバイス学習の要素技術を研究した。具体的には、オンデバイス学習アルゴリズムとその連合学習手法を研究した。また、環境変化を検出して自律的に追加学習をトリガーさせるために、コンセプトドリフト検知アルゴリズムを研究した。慶大松谷グループはオンデバイス学習を無線センサノードに応用し、「貼り付けるだけ異常検知器」を開発した。慶大近藤グループはオンデバイス学習器を管理するためのクラウド側ソフトウェアを構築した。フィックスターズグループはオンデバイス学習技術のスマートインダストリーへの応用に向けていくつかの実証実験を行った。また、オンデバイス

学習を用いたロボットアームの動きの異常検知ソフトウェア OAD-iOS を開発し、タブレット端末上でリアルタイム動作させた。理研グループはオンデバイス学習を用いた気象データ同化手法を研究した。具体的には、データ同化による気象予測モデルの改善に寄与しない観測データを気象センサ側(エッジ側)で取り除く技術を研究した。パナソニックグループはオンデバイス学習アルゴリズムを様々な家電のトラッキング火災の予兆検知に応用し、同社のモデルハウスにて実証実験を行った。また、実環境への埋め込みを想定したプロトタイプ機の研究開発や家電データセットの収集も行った。ロームグループはオンデバイス学習機能を有し、僅か 30mW 程度で推論と学習ができる超小型 AI チップを開発し、モータなどの回転機械の異常検知に成功した。

上記成果を当初のビジョンと照らし合わせると、まず、慶大グループによってオンデバイス学習とその連合学習、および、コンセプトドリフト検知と連動したオンデバイス学習によって自律的で環境変動に強いインテリジェンスを実現するための基礎ができたと言える。ロームグループによってオンデバイス学習機能の集積回路化に成功した。ロームグループ、フィックスターズグループによってそれぞれ産業分野への応用が進み、理研グループ、パナソニックグループによってそれぞれ気象センサ、家電を対象とした防災分野への応用が行われるなど、オンデバイス学習は様々な分野に応用され、ローエンドエッジ AI としての有用性を実証することができた。

## (2) 顕著な成果

<優れた基礎研究としての成果>

### 1. オンデバイス学習アルゴリズムの開発

概要:オンデバイス学習アルゴリズムに関する提案論文が IEEE Transactions on Computers に掲載された。Featured Paper in the July 2020 Issue にも選ばれ、IEEE Transactions on Computers Multimedia のウェブサイトにて英語と日本語の紹介動画が掲載された。また、オンデバイス学習のための連合学習アルゴリズムに関する提案論文が IEEE Access に掲載された。試作品として 4ドル程度の Raspberry Pi Pico 上で動作する「貼り付けるだけ異常検知器」を開発し、イノベーション・ジャパン 2022 にて講演し、CEATEC 2022 にてデモ展示を行った。

### 2. 海外キープレイヤーとの比較と優位性

概要:tinyML にて On-Device Learning に特化したフォーラム<sup>1</sup>が行われ、招待講演者として MIT、慶大(代表者)、Duke 大、McGill 大、ミラノ工科大、Siemens(ミュンヘン工科大)、Google、IBM、Qualcomm、ST Micro などが登壇した。いくつかのグループが我々と近い技術を研究開発していることが分かったが、他者のそれには我々にとってブレークスルーとなった計算コストの削減手法やデータの多峰性への対処手法は示されておらず、我々の手法は依然として優位性を保っていることを確認した。

### 3. オンデバイス学習チップの開発

概要:ロームグループがオンデバイス学習技術機能を有する超小型 SoC(System-on-Chip)を開発

---

<sup>1</sup> <https://www.tinyml.org/event/on-device-learning/>

した。チップは同社の 130nm プロセスで製造され、僅か 30mW 程度でニューラルネットワークの学習と推論ができる。本成果は日本経済新聞(関西版・電子版)、日経クロステック、日刊工業新聞、電波新聞、京都新聞、化学工業日報、電子デバイス産業新聞などで報じられた。本チップについてはイノベーション・ジャパン 2022 にて講演し、CEATEC 2022 にて展示を行った。

< 科学技術イノベーションに大きく寄与する成果 >

#### 1. チップの量産化計画

概要: オンデバイス学習機能を有するロームグループの SoC について、同社による 2022 年 9 月 27 日のプレスリリース「クラウドサーバー不要、現場でリアルタイムの故障予知を実現する、数 10mW 超低消費電力のオンデバイス学習 AI チップを開発」にて、「モータやセンサの故障予知のために IC 製品へ搭載することを予定しています。2023 年度に製品化着手、2024 年度に製品として量産予定です。」とあり、研究成果が量産化される可能性が出てきた。

#### 2. モデルハウスでの実証実験

概要: パナソニックグループは家電製品の動作中においても電源火災の予兆検出に成功した。内部構造がヒータのみの家電製品では以前から予兆検出に成功していたが、モータ、インバータ、マグネトロン等による誤検知を低減する手法を開発し、応用可能な家電製品の幅が大きく広がった。パナソニックグループのモデルハウスにて、実環境を想定した実証実験を行い、実環境でのノイズ耐性、複数機器、長時間動作時の安定性について検証した点も実用化に向けた進捗である。

#### 3. 家電データセットの構築・公開

概要: パナソニックグループは 14 種類の家電を対象に正常動作時の電流・電圧データ、および、トラッキング劣化の兆候が含まれている異常データを合計 390 個程度収集した。さらに、複数の家電を同時動作させた場合のデータセットを合計 210 個程度作成した。このようにして作成したデータセットは AI 開発用途での研究機関等への一般公開を前提に、2021 年度から一部機関に先行公開しデータセット・評価環境の整理をスタートしている。

< 代表的な論文 >

1. Mineto Tsukada, Masaaki Kondo, and Hiroki Matsutani, “A Neural Network-Based On-device Learning Anomaly Detector for Edge Devices”, IEEE Transactions on Computers (TC), vol.69, no.7, pp.1027-1044, Jul. 2020. (Featured Paper in July 2020 Issue of IEEE TC)

概要: オンデバイス学習アルゴリズムの基本部分、および、FPGA を対象とした小規模回路化に関する論文。ニューラルネットワークの逐次学習アルゴリズムとして OS-ELM<sup>2</sup>が知られている。本論文では OS-ELM をベースに計算の簡略化や軽量な忘却手法を提案し、これをオートエンコーダと組み合わせてエッジデバイス上で学習できる異常検知器を実現した。さらにこれを小規模 FPGA 上

---

<sup>2</sup> N.-y. Liang, G.-b. Huang, P. Saratchandran, and N. Sundararajan, “A Fast and Accurate Online Sequential Learning Algorithm for Feedforward Networks”, IEEE Transactions on Neural Networks, vol.17, no.6, pp.1411-1423, 2006.

に実装し、面積、性能、精度、消費電力などの点で評価した。

2. Rei Ito, Mineto Tsukada, and Hiroki Matsutani, “An On-Device Federated Learning Approach for Cooperative Model Update between Edge Devices”, IEEE Access, vol.9, pp.92986-92998, Jun. 2021.

概要: 上記の OS-ELM ベースのオンデバイス学習器を対象とした連合学習手法を提案した。連合学習に参加するクライアントがローカルに学習した重みパラメータをサーバに集めてマージするのではなく、本提案手法では各ノードの重みパラメータから生成した中間データを参加ノード間で直接交換する。集めた中間データを所定のアルゴリズムにしたがって統合することで、それらをマージした重みパラメータが得られる。重みパラメータのマージが分散的に行われる点で従来の中央集権的な連合学習とは異なる。

3. Hiroki Matsutani, Mineto Tsukada, and Masaaki Kondo, “On-Device Learning: A Neural Network Based Field-Trainable Edge AI”, arXiv:2203.01077, May 2022.

概要: 本論文は現時点ではまだ arXiv Preprint の状態ではあるが、LinkedIn など SNS での反響が大きかったためここに含めた。上記 1. のオンデバイス学習アルゴリズムの基本部分に加えて、データの多峰性への対処やコンセプトドリフト検知と連動した自律的追加学習などこれまでバラバラに提案していた技術を平易にまとめた解説論文である。これらを Raspberry Pi Pico 上に実装した「貼り付けるだけ異常検知器」についても紹介している。

## §2 研究実施体制

(1) 研究チームの体制について

### ① 慶大松谷(代表者)グループ

研究代表者: 松谷 宏紀 (慶應義塾大学理工学部 教授)

研究項目

【A1】オンデバイス学習を基にした協調型モデル更新(フェデレーション)の確立

【A4】安全設計のためのデータ前処理手法の確立

【A5】オンデバイス学習チップのフロントエンド設計

【B6】オンデバイス学習を基にした協調型モデル更新(フェデレーション)の応用

【B7】研究成果の更なる応用展開

【C1】工業データセットに向けた PoC の実施

【C2】工業データセット作成

### ② 慶大近藤(旧東大)グループ

主たる共同研究者: 近藤 正章 (慶應義塾大学理工学部 教授)

研究項目

【A1】オンデバイス学習を基にした協調型モデル更新(フェデレーション)の確立

【A3】オンデバイス学習のクラウド連携による認識処理の高度化

【B6】オンデバイス学習を基にした協調型モデル更新(フェデレーション)の応用

【B7】研究成果の更なる応用展開

【C1】工業データセットに向けた PoC の実施

【C2】工業データセット作成

③ フィックスターズグループ

主たる共同研究者:塩田 靖彦 (株式会社フィックスターズ 参事)

研究項目

【A3】オンデバイス学習のクラウド連携による認識処理の高度化

【B1】オンデバイス学習技術のスマートインダストリーへの応用

【B7】研究成果の更なる応用展開

【C1】工業データセットに向けた PoC の実施

【C2】工業データセット作成

④ 理研グループ

主たる共同研究者:三好 建正 (理化学研究所計算科学研究センター チームリーダー)

研究項目

【A2】オンデバイス学習を用いた新たな気象データ同化手法の確立

【B4】気象予測のシミュレーション環境構築と有効性評価

【B7】研究成果の更なる応用展開

⑤ パナソニックグループ

主たる共同研究者:岡本 球夫 (パナソニック株式会社プロダクト解析センター 課長)

研究項目

【A4】安全設計のためのデータ前処理手法の確立

【B2】安全設計のための実データ収集・分析

【B3】安全設計のためのプロトタイプ開発と実証実験

【B7】研究成果の更なる応用展開

【C3】家電データセットに向けた調査

【C4】家電データセット作成

⑥ ロームグループ

主たる共同研究者:西山 高浩 (ローム株式会社回路技術開発部 課長)

研究項目

【A5】オンデバイス学習チップのフロントエンド設計

【B5】オンデバイス学習チップの試作とセンシングへの応用

【B7】研究成果の更なる応用展開

(2) 国内外の研究者や産業界等との連携によるネットワーク形成の状況について

2023 年度より AIP 加速課題に採択され、本 CREST の慶大グループとパナソニックグループに加え、立命館大学とオンデバイス学習の信頼性に関する研究を実施している。また、2023 年度よりテキサス大学オースティン校ともオンデバイス学習に関する共同研究を実施している。