

# 計算資源の限られた小型センサ端末のための 勾配ブースティング連合学習

山下 優衣<sup>1,a)</sup> 田谷 昭仁<sup>2,b)</sup> 戸辺 義人<sup>2,c)</sup>

**概要:** 近年、気軽に身に着けることのできるウェアラブル端末が普及している。このような端末から取得可能なデータの処理には機械学習が用いられることが多いが、より高精度な予測モデルを作るためには大量のデータが必要となる。サーバを用いてデータを収集し、それらをビッグデータとして学習することも可能であるが、サーバの利用は管理の手間やデータの極集中が生じることと収集したデータのプライバシーが保護されないことが課題となる。本稿では、これらの課題を解決するため、サーバを用いずに端末間で分散学習を行う機械学習手法を提案する。提案手法では、計算リソースの限られたウェアラブル端末を想定し、決定木の勾配ブースティングを用いる。また、プライバシーを保護するために端末間ではデータではなく学習モデルを共有する。

## 1. はじめに

近年、IoT (Internet of Things) という概念が幅広く知られるようになってきた。IoT 技術を用いたものには、家庭内の家電をスマートフォンから遠隔で操作することができるようなスマートホームやインフラの整備を補助し快適な街作りを目指すようなスマートシティがあり注目を集めている。さらには、センサが搭載されたスマートフォンだけでなく、さまざまなウェアラブル端末も普及している。ウェアラブル端末は、腕時計型のスマートウォッチや指輪型のスマートリングが登場しているように小型化が進み、気軽に装着することができるようになってきている。

このような端末には、機器自身にセンサが搭載されており、多くのセンシングデータを取得することが可能である。センシングデータを使用した研究は、生体情報から感情認識を行い活用するもの [1], [2] や加速度計から行動認識をするもの [3] などがある。これらの研究の多くは機械学習を用いているが、深層学習によるものが多く台頭している [4], [5]。しかし、ウェアラブル端末は電力やメモリなど計算資源が限られているため、計算量が多い深層学習は

不向きである。計算資源に制限のある小型なセンサ端末においても効率的にデータを訓練し、モデルを生成するためには、深層学習に比べて少ない消費電力で比較的計算処理が軽い学習手法を適用する必要がある。そのため、本稿においては計算資源をあまり必要とせずに学習が可能な決定木およびそのアンサンブル学習である GBDT (Gradient Boosting Decision Tree) [6] を用いる。

また、より高い性能の機械学習モデルを作成するには大量のデータが必要となる。そのため、データセンタなどに個人の所有しているデータを収集し、それらをまとめて機械学習へ適用することが考えられる。しかし、このような方法はサーバの継続的なメンテナンスを要するだけでなく、データ収集が容易にできるプラットフォームと呼ばれる一部の大規模な企業に大量のデータや精度の高い機械学習モデルが集中することが考えられる。データが一極に集中していると、これらを所持している企業がサービスを停止した際に、収集したデータやモデルを失う可能性が生じるといった点が課題となる。そこで、本稿ではサーバを使用せずに複数台の端末間で直接通信することで自律協調的に分散学習する手法を提案する。

さらに、データ収集においてプライバシーの保護が課題となる。ウェアラブル端末から取得することができるセンサデータには、位置情報などの活動情報、心拍数や体温のような生体情報があるが、これらは個人が特定できたり人に知られたくないような情報を含む場合が多い。したがって、このようなデータを直接他人へ渡さず、プライバシーを保護することが分散学習において必要となる。プラ

<sup>1</sup> 青山学院大学大学院理工学研究科理工学専攻  
Graduate School of Science and Engineering, Aoyama Gakuin University

<sup>2</sup> 青山学院大学理工学部情報テクノロジー学科  
Department of Integrated Information Technology, Aoyama Gakuin University

a) yui20@rcl-aoyama.jp

b) taya@it.aoyama.ac.jp

c) y.tobe@rcl-aoyama.jp

イバシ保護を目的とした分散学習アルゴリズムには連合学習 (FL: Federated Learning) [7] がある。FL はローカルデータを共有せずに、分散された複数台の機器で構築されたニューラルネットワークモデルを共有することでデータ漏洩を防いでいる。提案手法においてもこの考え方を適用し、ローカルデータは端末間で共有せずプライバシーを保護することが求められる。

以上の背景から、深層学習が不向きな小型センサ端末向けに FL を決定木によって実現する必要がある。また前述の通り、自律協調的な分散学習を行うためにはこれらをサーバレスで行いたいと考える。本稿では、以上の目的を実現するための GBDT によるサーバレス FL アルゴリズムを提案する。提案アルゴリズムでは、端末間での通信時には個々が所有するローカルデータではなく機械学習モデルを共有することで、プライバシー保護を達成する。さらに、端末が所持する単独のデータのみで決定木を学習するのではなく、各端末で学習された決定木を交換し、自身が学習した決定木と他端末から受け取った決定木を次のモデルの学習に使用することでサーバレス分散学習を実現する。

本稿では、第2章で関連研究について述べる。第3章では検討モデルについて述べ、第4章では提案アルゴリズム、第5章では評価結果および考察、第6章では本論文の結論として、今後の課題と発展について述べる。

## 2. 関連研究

ローカルデータではなく、機械学習モデルを共有することでプライバシーの保護を達成する分散学習アルゴリズムに FL がある [7]。FL は、クライアントごとにローカルデータでモデルを計算し、そのモデルをサーバへ送る。そしてサーバではモデルを集約し、グローバルモデルの構築をする。これらのグローバルモデルはクライアントへ送り返され、クライアントで再び学習する際に使用する。この際、学習にはニューラルネットワークを適用している。モデルの集約と更新を繰り返すことで機械学習の精度の向上させることができ、スマートフォンユーザの感情推定や行動認識などにおいても使用されている [8]。

本稿では、端末での機械学習手法に FL で用いているニューラルネットワークではなく GBDT を適用し、弱学習器である決定木の共有をすることでプライバシーの保護をする。また、FL ではサーバを用いることでモデルを集約、計算をしているが、提案手法ではサーバを用いず端末間のみで通信することで分散学習を行う。

本稿で用いる機械学習手法の GBDT は、複数のモデルを組み合わせて学習するアンサンブル手法であるブースティングを決定木に適用しており、高い予測精度と計算効率から産業界だけでなく学界においても広く使用されている [9]。FL フレームワークと決定木のブースティングアルゴリズムを組み合わせることでプライバシーを保護する研究も

されている。FL の条件下で決定木ベースの学習を行っている Pivot[10] や XGBoost (eXtreme Gradient Boosting) [11] の学習を実現している SecureBoost[12] では、各クライアント毎にあるユーザの異なる特徴量を所持し、サーバにあたる企業がモデルを作成することで分散学習がなされている。これらの研究は、FL フレームワークにおいて決定木の分散学習を行うという点が本研究と共通しているが、サーバを用いない環境下において個々の端末で計算を完結させることができていない。本研究では、個人の端末単位のモデルの構築を行うため、データは個々で所有しておく必要がある。これらのプライバシーを保護するために学習済みのモデルを共有することを考える。

## 3. システムモデル

本章では、提案アルゴリズムを適用するためのシステムモデルについて述べる。提案アルゴリズムは、サーバを用いず隣接端末間のみで通信することができるマルチホップネットワークでの接続を想定する。このシステムモデルを図1に示す。

提案アルゴリズムは、スマートウォッチなどのウェアラブル端末を使用することを想定としている。これらの端末では、搭載されているセンサからさまざまなデータを取得することができる。そのようなデータのうち、心拍数や呼吸数などを含む生体情報を用いてストレス度を測るようなヘルスケアアプリケーションを各端末で使用する場合を例として考える。ストレス度を予測するにあたり必要な生体情報は、他人にはあまり知られたくないプライバシーに関わるデータが含まれる可能性がある。そのため、データを他の端末へ直接共有することはできず、データではなく端末ごとに独立して機械学習モデルを訓練し、定期的に訓練したモデルを共有する。さらに、モデルの共有は端末所有者の所属しているコミュニティ間などで、知り合いのみで行うことを想定としている。例えば、端末を使用している学生が研究室、サークル活動、アルバイトのようなコミュニティに属しているとき、それぞれのグループにおいてモデルを共有する。他の端末から共有されたモデルを訓練しておくことで、同じ研究室に属している他の人の情報を、直接データを共有せずにサークルやアルバイトといった別のコミュニティへも共有することができ、結果として、他社の情報を含む複数人のデータを訓練したモデルを作成できるようになる。自身のモデルと他の端末から共有されたモデルを用いたモデルを更新は以下のように行う。

端末  $i$  が所有するローカルデータセットを  $D_i$  と定義すると、端末  $i$  は  $D_i$  より予測モデル  $F_i$  を訓練する。また、端末  $i$  でブースティング回数  $j$  回目に学習した決定木を  $f_{i,j}$  とする。本システムでは隣接端末と  $D_i$  を共有しない代わりに、 $f_{i,j}$  を共有する。予測モデル  $F_i$  は、自身で学習した決定木と他端末から受け取った決定木から構成される。




図 1 システムモデル

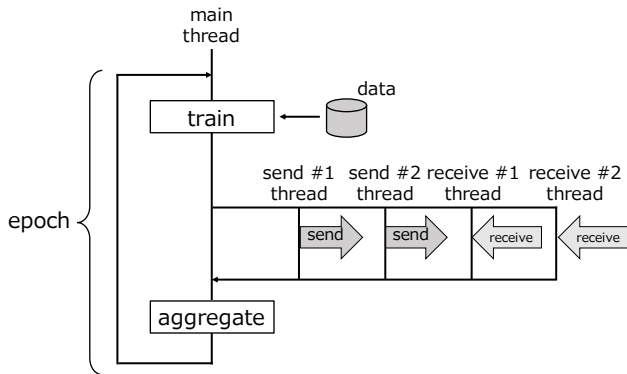


図 2 端末間通信のシーケンス図

隣接端末数を  $n$  としたとき、 $n$  台の端末 id を  $k_a$  で表す。ブースティング総数が  $m$  回のとき、 $F_i$  は以下のように定義できる。

$$F_i = \{f_{p,q} \mid p = i, k_1, \dots, k_n, q = 0, \dots, m\}. \quad (1)$$

本稿では、 $m$  は全端末で共通とし、また全端末同じタイミングで決定木の送受信を行う同期処理を想定とする。

#### 4. GBDT によるサーバレス FL

本章では、サーバを使用せずに学習器を共有することで性能の良いモデルの取得を目指す提案アルゴリズムについて述べる。

提案アルゴリズムでは、ローカルデータを訓練し、決定木を構築する。構築した決定木は隣接端末へ共有するために端末間で通信し、送受信の完了後は、自身の端末で作成したモデルと他端末から受信したモデルとを集約する。その後、これらのモデルを使用して次のモデルを構築していく。隣接端末数を 2 としたときの分散学習の流れを図 2 に示す。訓練、通信、集約の一連の流れを 1 エポックとし、これをブースティング総数である  $m$  回繰り返す。本章では、端末での決定木の学習を 4.1、モデルの送受信を 4.2、木の集約を 4.3 で述べる。

##### 4.1 決定木の構築

本節では、GBDT モデルの学習に用いる弱学習器である決定木の構築について述べる。GBDT は、前の予測モデルの残差を用いて次の決定木を構築することを繰り返し、全ての決定木の合計が最終的な予測モデルとなる。提案アル

ゴリズムでは、始めに端末  $i$  において 1 本目に構築する決定木をローカルデータ  $D_i$  を訓練することで作成する。1 本目の決定木はブースティング回数  $j = 0$  であり、

$$f_{i,0} \leftarrow \text{train} \{D_i\}, \quad (2)$$

と表せる。ここで  $\text{train} \{D\}$  はデータセット  $D$  で学習することを表す。

次に  $j \geq 1$  の場合、残差を用いて次の決定木を学習する。正解データを  $y$ 、 $j$  回目の学習での予測値を  $h_{i,j}$  とすると、 $f_{i,j}$  は 1 つ前のモデル  $f_{i,j-1}$  と残差に学習率  $\eta$  を掛け合わせたものの和となる。

$$f_{i,j} = f_{i,j-1} + \eta(y - h_{i,j}) \quad (j \geq 1). \quad (3)$$

$h_{i,j}$  の計算については 4.3 にて述べる。

##### 4.2 端末間通信の実装

本節では、決定木の共有を行うための端末間通信について述べる。本研究において、端末間の通信はソケット通信で実装する。各端末は隣接端末ごとに送信用と受信用のスレッドをそれぞれ用意することで、決定木を端末間で非同期に送受信することを達成する。

4.1 で述べた  $f_{i,j}$  の計算を終えた後、必要な数のスレッドを作成し、 $n$  台の隣接端末と通信を始める。図 2 では、2 台の隣接端末との通信を想定しているため、送信用のスレッドとして  $\text{send \#1 / \#2 thread}$  の 2 つ、受信用として  $\text{receive \#1 / \#2 thread}$  の 2 つを作成している。各スレッドで送信または受信を開始すると、メインスレッドは全てのスレッドが処理を終えるのを待つ。終了後は隣接端末から受け取った  $n$  本の決定木をメインのスレッドで集約する。集約部分の計算は次節に示す。

##### 4.3 モデルの集約

本節では、決定木の共有後のモデルの更新方法について述べる。隣接端末との通信の後、端末  $i$  は  $n$  本の決定木を受け取る。他端末から受信した決定木を  $k_a$  を用いて  $f_{k_a,j}$  ( $a = 1, \dots, n$ ) と表すと、受信後は自身が構築した  $f_{i,j}$  と他端末の  $f_{k_a,j}$  から構成される。それぞれの決定木の予測値を  $g_{i,j}$  としたとき、初回の計算時 ( $j = 0$ ) のみ予測値  $h_{i,j}$  は目的変数の平均を用いるため、隣接端末数が  $n$  のとき  $h_{i,0}$  は次式で求める。

$$h_{i,0} = \frac{1}{n+1} \left( g_{i,0} + \sum_{a=1}^n g_{k_a,0} \right). \quad (4)$$

一方で 2 回目以降 ( $j \geq 1$ ) は、決定木交換後の予測値  $h_{i,j}$  の計算に残差の和を用い、平均としないため、

$$h_{i,j} = g_{i,j} + \sum_{a=1}^n g_{k_a,j}, \quad (5)$$

**Algorithm 1** GBDDT-Based FL

---

```

1:  $f_{i,0} \leftarrow \text{train by } D_i$ 
2: send and receive trees
3:  $g_{p,0} \leftarrow \text{predict using } f_{p,0} \ (p = i, k_1, \dots, k_n)$ 
4:  $h_{i,0} = \frac{1}{n+1} (g_{i,0} + \sum_{a=1}^n g_{k_a,0})$ 
5: for  $j = 1$  to  $m$  do
6:    $f_{i,j} = f_{i,j-1} + \eta (y - h_{i,j-1})$ 
7:   send and receive trees
8:    $g_{p,0} \leftarrow \text{predict using } f_{p,0} \ (p = i, k_1, \dots, k_n)$ 
9:    $h_{i,j} = g_{i,j} + \sum_{a=1}^n g_{k_a,j}$ 
10: end for
11:  $F_i = \{f_{p,q} \mid p = i, k_1, \dots, k_n, q = 0, \dots, m\}$ 

```

---

とした。これらを用いて (3) を計算することでモデルを更新する。

GBDDT は全ての決定木の合計が最終的な予測モデルとなるため、最終モデルは次式となる。

$$F_i = \frac{1}{n+1} \left( f_{i,0} + \sum_{a=1}^n f_{k_a,0} \right) + \sum_{b=1}^{m-1} \left( f_{i,b} + \sum_{a=1}^n f_{k_a,b} \right). \quad (6)$$

端末  $i$  における提案アルゴリズムの擬似コードをアルゴリズム 1 に示す。

## 5. 評価

本章では、提案アルゴリズムの評価結果および考察を述べる。

### 5.1 パラメータ設定

本節では、評価のためのシミュレーション設定について示す。評価には、図 3 に示すトポロジーのように、端末数 10 のマルチホップネットワーク接続モデルを用いた。図中の数字は端末 id を表しており、端末 0 の隣接端末数は  $n = 4$  となり、端末 1, 2, 8, 9 と決定木を共有するが、その他の端末とは共有することができない。評価実験では、 $n$  は全端末共通で 4 となるようシミュレーションを行った。

また、提案アルゴリズムではブースティング回数  $m$  と同じ回数、隣接端末間で決定木を交換する。最終モデルを構築する木の総数は、隣接端末数とブースティング回数に依存し、端末  $i$  における木の総数を  $t_i$  とすると

$$t_i = m(n+1), \quad (7)$$

と表せる。シミュレーションは  $m = 20$  として行ったため、提案手法では全端末で  $t_i = 100$  となる。

### 5.2 データセット

評価には機械学習アルゴリズムの画像データセット MNIST[13] を使用した。データの分割は、端末ごとにラベルに偏りが無い IID (Independent and Identically Distributed) データ、所持するローカルデータが所有者によ




図 3 シミュレーションモデル

表 1 non-IID 条件下の訓練データの分割

端末 id	所持する正解ラベル	データ総数
0, 5	0, 1, 2, 3	1,000 / 端末
1, 6	2, 3, 4, 5	1,000 / 端末
2, 7	4, 5, 6, 7	1,000 / 端末
3, 8	6, 7, 8, 9	1,000 / 端末
4, 9	8, 9, 0, 1	1,000 / 端末

て異なる non-IID データの 2 つの場合を想定して行った。IID データでは、「0」から「9」までの正解ラベルを持つ MNIST を各端末が重複なく 1,000 の訓練データを持つよう分割した。non-IID では表 1 のように分割し、それぞれの端末が持つ訓練データ数は各ラベルが 250 ずつ、計 1,000 となる。さらに、評価するためにラベルに偏りのない 10,000 のテストデータを用意した。テストデータは各端末における提案アルゴリズムの評価および次節で述べる比較指標の検証にも共通で用いた。

### 5.3 比較指標

本節では、提案アルゴリズムを評価するにあたり使用した評価指標について述べる。

- GBDDT with all data (all data) : 各端末の持つローカルデータをサーバに集約し、それらの全データから GBDDT を構築することを想定した指標を GBDDT with all data (all data) とする。これはローカルデータを共有しているためプライバシーを考慮しておらず、またサーバにデータが集中している状況である。使用する端末の総数を  $N$  とすると、本指標のモデル  $G_{\text{all}}$  は次式で表される。

$$G_{\text{all}} \leftarrow \text{train} \{D_0, D_1, \dots, D_{N-1}\}. \quad (8)$$

- GBDDT with local data (local data): 端末ごとにローカルデータを学習して GBDDT を構築したものを GBDDT with local data (local data) とする。これは端末間で決定木を交換することなく、自身の端末のみで学習を繰り返したもので、分散学習を行っていない。この指標は端末ごとに計算されるため、

$$G_i \leftarrow \text{train} \{D_i\} \quad (i = 0, 1, \dots, N-1), \quad (9)$$

となる。

表 2 評価に用いたパラメータ

	all data	local data	proposal
訓練データ数	10,000	1,000 / 端末	1,000 / 端末
テストデータ数		10,000	
学習率		0.3	
木の深さの最大値		5	




図 4 IID 条件下での繰り返し回数による評価結果




図 5 IID 条件下での決定木の本数による評価結果

表 3 IID 条件下での各指標の最終精度

	20 iterations			100 trees		
	all	local	proposal	all	local	proposal
Acc.	0.819	0.729	0.747	0.895	0.782	0.747

## 5.4 評価結果

本節では、5.1 から 5.3 の設定下で行ったシミュレーションの評価結果を示す。提案アルゴリズムの評価は、図 3 のように端末数を 10、全ての端末で隣接端末数  $n = 4$  とし、繰り返し回数を  $m = 20$  に設定した。提案アルゴリズム (proposal) と 5.3 で述べた 2 つの比較指標 (all data, local data) で用いたパラメータを表 2 にまとめ、IID, non-IID 条件下におけるそれぞれの評価結果を表す。

### 5.4.1 IID データ

IID データでの評価結果を図 4, 図 5 に示す。また、それぞれの最終的な精度を表 3 にまとめる。図 4 は横軸にブースティングの回数を示しており、20 回終了時の精度は、比較指標の all data は約 81.9% となり、local data の精度は約 72.8% であった。提案アルゴリズムにおいては、交換前

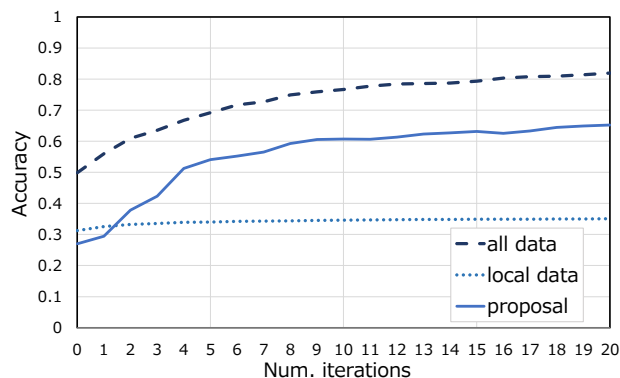


図 6 non-IID 条件下での繰り返し回数による評価結果

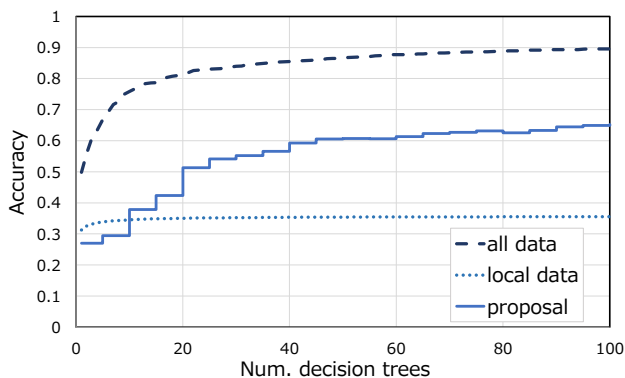


図 7 non-IID 条件下での決定木の本数による評価結果

表 4 non-IID 条件下での各指標の最終精度

	20 iterations			100 trees		
	all	local	proposal	all	local	proposal
Acc.	0.819	0.351	0.653	0.895	0.356	0.653

の決定木が 1 本である初回の学習の精度は約 37.3% であり、交換を繰り返すことで精度が向上し、100 本の決定木を持つ 20 回終了時には約 74.7% となった。さらに、2 回交換後に提案手法は local data を上回る精度を達成することができた。また、提案手法は 1 エポックごとに 5 本ずつ決定木が増えるため、構築された決定木の本数で比較を行うために木の本数を横軸としたグラフを図 5 に示している。比較指標において GBDT モデルが 100 本の決定木から構成される際の精度は、all data で約 89.5%、local data は約 78.2% となった。IID 条件下では、同数の決定木を持つような条件では、提案手法は分散学習を行わない local data の精度を上回ることができなかったが、エポック数を統一した際には local data よりも高い精度を達成することができた。

### 5.4.2 non-IID データ

IID データと同様に non-IID データでの評価においても、ブースティングの回数による比較と決定木の本数による比較を行った。non-IID データでの評価結果を図 6, 図 7, それぞれの最終的な精度を表 4 に示す。all data は IID と

non-IID の区別がないため 5.4.1 で述べた精度と同じであり、20 回の繰り返し終了時は約 81.9%であった。一方で、分散学習を行わない場合の local data は、4 つのラベルしか所持していないため IID の場合よりも低い約 35.1%であった。提案アルゴリズムにおいても、交換前の各端末は 4 つのラベルしか所有していないため、1 回目の精度は約 27.0%であったが、学習の繰り返しにより約 65.3%まで向上した。さらに non-IID データでは、決定木の本数と比較した場合にも提案手法は local data を上回る結果となり、100 本のときの精度はそれぞれ約 65.3%、約 35.6%であった。以上の結果は、交換によって自身が所持していないラベルの情報を持つ決定木を受け取り、それらを学習できていることを示している。また、繰り返し回数が増加するにつれ精度が高くなっていることから、より多くの端末間での通信や繰り返しの交換が性能向上に繋がると考察できる。

5.4.1 の IID データの場合と non-IID の場合を比較してみると、提案アルゴリズムは端末間でばらつきのあるデータを所持している non-IID データにおいて、より効果的であることがわかる。提案アルゴリズムは、所持するデータに個人差があるような場面で使用することを想定としているため、以上の結果は、実用性を示すことができると考えられる。

## 6. 結論

本稿では、サーバレスで GBDT を用いた分散学習のアルゴリズムを提案した。提案アルゴリズムは、決定木の交換と学習を繰り返す分散学習を行うことで、各端末においてローカルデータのみで学習した場合を上回ることができた。ゆえに、GBDT モデルの弱学習器である決定木を交換することで、プライバシーを保護しながら情報の共有ができ、交換と学習の繰り返して精度が向上することが示せた。さらに、IID データ、non-IID データの 2 条件による評価から、提案アルゴリズムはデータに偏りのある non-IID データにおいてより効果的であることがわかった。

今後の展望としては以下が挙げられる。本稿における提案アルゴリズムは、モデルの学習を終えると木の送受信を始め、全ての隣接端末から木の受信を終えるのを待つため、全端末で訓練、送受信、集約のエポックのタイミングが同じである同期処理による実装であった。しかし、本アルゴリズムを実際に使用する場合、学習時間や送受信の時間に差が生じることもあるため、端末ごとに都合の良いタイミングで接続相手へモデルを送信することができる非同期処理で通信できることが望ましい。そのため、アルゴリズムに改良を加え、非同期処理の実現を考える。また、今回の評価には MNIST のデータセットを用いているが、今後はウェアラブル端末で実際に取得することができる生体情報や加速度計などのデータを用い、行動の分類や病気の予測をすることで実用性の検証を行うことを考える。さらに、

単純なシミュレーションモデルだけでなく、ユーザの行動範囲によって通信範囲が変化するような環境を想定した評価を行うことも今後の課題とする。

**謝辞** 本研究は科研費 21K17734 の助成を受けたものである。

## 参考文献

- [1] Ayata, D., Yaslan, Y. and E.Kamasak, M.: Emotion Based Music Recommendation System Using Wearable Physiological Sensors, *IEEE Transactions on Consumer Electronics*, Vol.64, No.2, pp.196–203 (2018).
- [2] Kanjo, E., Younis, E.M.G. and Sherkat, N.: Towards Unravelling the Relationship between On-Body, Environmental and Emotion Data using Sensor Information Fusion Approach, *Information Fusion*, Vol.40, pp.18–31 (2018).
- [3] Siirtola, P. and Röning, J.: Recognizing Human Activities User-Independently on Smartphones Based on Accelerometer Data, *International Journal of Interactive Multimedia and Artificial Intelligence*, Vol.1, No.5, pp.38–45 (2012).
- [4] Ali, F., El-Sappagh, S., Islam, S.M.R., Kwak, D., Ali, A., Imran, M., Kwak, K.: A Smart Healthcare Monitoring System for Heart Disease Prediction Based on Ensemble Deep Learning and Feature Fusion, *Information Fusion*, Vol.63, pp.208–222 (2020).
- [5] Chen, L., Zhang, Y. and Peng, L.: METIER: A Deep Multi-Task Learning Based Activity and User Recognition Model Using Wearable Sensors, *Proc. of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, Vol.4, No.1, pp.1–18(2020).
- [6] Friedman H.J.: Greedy Function Approximation: A Gradient Boosting Machine, *The Annals of Statistics*, Vol.29, No.5, pp.1189–1232(2001).
- [7] Konečný, J., McMahan, B.H., Yu, X.F., Richtárik, P., Suresh, T.A., Bacon, D.: Federated Learning: Strategies for Improving Communication Efficiency, *NIPS Workshop on Private Multi-Party Machine Learning* (2016).
- [8] Li, T., Sahu, K.A., Talwalkar, A., Smith, V.: Federated Learning: Challenges, Methods, and Future Directions, *IEEE Signal Processing Magazine*, Vol.37, No.3, pp.50–60(2020).
- [9] Fu, F., Jiang, J., Shao, Y., Cui, B.: An Experimental Evaluation of Large Scale GBDT Systems, *Proc. of the VLDB Endowment*, Vol.12, No.11 pp.1357–1370(2019).
- [10] Wu, Y., Cai, S., Xiao, X., Chen, G., Ooi, B.C.: Privacy preserving vertical federated learning for tree-based models, *Proc. of the VLDB Endowment*, Vol.13, No.12 (2020).
- [11] Chen, T., Guestrin, C.: XGBoost: A Scalable Tree Boosting System, *Proc. of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*(2016).
- [12] Cheng, K., Fan, T., Jin, Y., Liu, Y., Chen, T., Papadopoulos, D., Yang, Q.: SecureBoost: A Lossless Federated Learning Framework, *IEEE Intelligent Systems*(2021).
- [13] Yann LeCun: THE MNIST DATABASE of handwritten digits 入手先;<http://yann.lecun.com/exdb/mnist/> (参照 2021-06-25).