

RIS を用いた OTA 連合学習における省エネ技術の開発

代表研究者 江 易 翰 大阪公立大学大学院工学研究科 助教

1 はじめに

機械学習 (Machine Learning) は今日、正確な予測やビジネス上の意思決定を提供する可能性において、様々な新興アプリケーション (スマートヘルスケアや高度道路交通システムなど) に変革をもたらしている。従来の機械学習はクラウド上で行われ、モデルの学習と推論のためにデータセット全体への完全なアクセスが可能である。しかし、このようなクラウド中心のフレームワークは、複数のソースから生のデータコンテンツを収集することに依存しており、欧州連合一般データ保護規則 (General Data Protection Regulation : GDPR) [1] などのデータ保護に関する規則に抵触する可能性があり、必然的にセキュリティとプライバシーの問題につながる。

上記の課題を解決するために、連合学習 (Federated Learning) [2] は、パラメータサーバ (以下は「サーバ」という) が管理する単一の機械学習モデルをエッジデバイス (以下は「デバイス」という) が共同で学習することを可能にすることで、有望なソリューションとして発展してきた。連合学習を用いることで、デバイスは生データの内容を公開することなく学習プロセスに参加することができる。連合学習の最もよく知られた実現法の 1 つは、FedAvg (Federated Averaging) アルゴリズム [3] であり、サーバとデバイス間でモデルの集約と配布を繰り返し実行し、学習性能の向上を目指す。

モノの人工知能 (Artificial Internet of Things) [4] の時代には、無線接続を持つデバイスが FL プロセスに参加する可能性がある。無線信号の波形重畳特性を考慮し、デジタルモデルの代わりに局所的な勾配を集約する空中計算 (Over-The-Air Computation : OTA) [5] が登場し、過剰な帯域幅を消費することなく無線ネットワーク上で連合学習を行える OTA 連合学習が実行可能になった。先行研究によっては、様々な電力制御技術の設計に専念してきたが、再構成可能なインテリジェントサーフェス (Reconfigurable Intelligent Surface : RIS) の利用により OTA 連合学習システムの学習性能に利益をもたらすことができるかあまり研究されていない。

本研究では、RIS を用いた OTA 連合学習におけるデバイス側の送信電力、RIS 側の位相シフト及び基地局側の勾配回復の共同最適化に注目し、以下の 3 つのステップで構成されたアルゴリズムを提案する : RIS 側の位相シフト制御、デバイス側の送信電力制御、基地局側の勾配回復。計算機シミュレーションによって、提案法が比較方法より優れていることをわかった。また、デバイス間のデータ不均一度、RIS の要素数、デバイスまたは RIS の設置距離などのパラメータが学習及び省エネの性能への影響も評価した。

2 背景

2-1 連合学習

連合学習とは、分散型機械学習の一種で、よりセキュアな環境で機械学習を実行できるのが特徴である。従来の機械学習では、各デバイスが所有している生データを中央のサーバに集計して、サーバで学習を行っていた。一方連合学習では、各デバイスは生データをサーバに共有することなく学習を行うことができる。以下では、連合学習の最もよく知られたアルゴリズムである FedAvg に関して説明する。FedAvg アルゴリズムはモデル配布、ローカル学習、モデル集約、勾配平均という 4 つのステップから構成されている。まずモデル配布では、サーバはグローバルモデルを全デバイスに配布する。次に、ローカル学習では、各デバイスは自身が所有するローカルデータセットを使用してローカルモデルを更新する。モデル集約では、サーバは選択されたデバイスからローカルモデルを集約し、集約されたローカルモデルの平均に基づいてグローバルモデルを更新する。これらの手順を 1 回の通信ラウンドとし、予め定義された収束基準が満たされるまで、複数回の通信ラウンドにわたって進行する。先に述べたように、連合学習では各デバイスが所有する生データをアップロードしないので、病院や金融機関などのセキュアな環境が求められる現場で特に注目されている。

2-2 空中計算

空中計算とは、無線多重アクセスチャネルの信号重畳み込み特性を利用した通信及び計算のことである。従来の通信手法では、基地局が多数のデバイスから信号を受信して処理する場合、まず各デバイスからの信号を順番に受信し、最後に統計処理がなされる。つまり、通信タスクと計算タスクが完全に分離されている。この方法では、デバイスの数が増加した場合に、送信衝突などの問題が発生する可能性がある。一方、OTA では、図 1 に示すように、チャネル内の信号の重ね合わせによって関数を計算することが意図されている。この方法では、どのデバイスからどのデータが送られてきたかを区別することは不可能である。しかし、そのような情報を必要としない場合、つまりデータの合計値などの統計的な値だけを必要とする場合には、OTA 方式はデータの送受信に要する時間を大幅に短縮し、送信の衝突などの問題を解決することができる。連合学習では、サーバ側で行われる計算は平均などの統計演算のみであり、どのデバイスの情報を利用するかを知る必要がないため、OTA 方式は有効である。




図 1：空中計算の概要図。

2-3 OTA 連合学習

IoT の時代において、通常はデバイスが無線インターフェース（5G、Wi-Fi、Bluetooth など）を介してインターネットに接続している。これに関連し、膨大な数のデバイスからのアナログモデルのアップロードを支援するために OTA 連合学習が提案された。OTA 連合学習では、デバイスは同じ無線リソースを用いてローカルモデルの更新情報を同時に送信することができる（図 2 を参照）。その後、マルチアクセスの無線信号の重畳特性を利用することで、基地局が受信した無線信号からローカルモデル集約を計算する。複数のデバイスが直交チャネルを使用して送信する従来の直交マルチアクセスと比較して、OTA 連合学習は無線通信波形の重畳特性の活用により、必要な無線通信リソースを大幅に削減でき、それにより無線環境におけるデバイスによる膨大な量のアクセスを支えることが可能である。

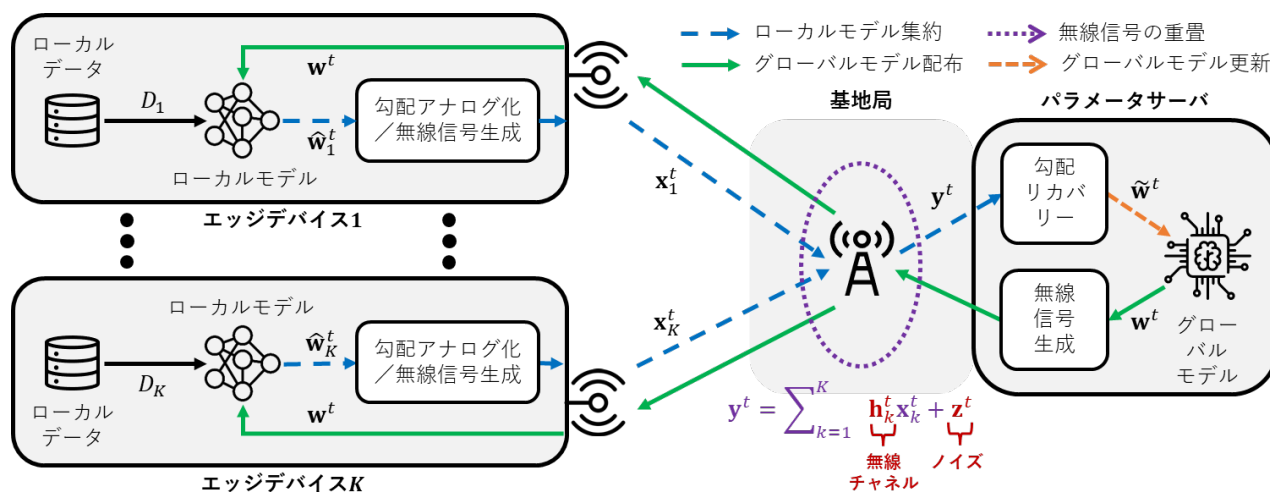


図 2：OTA 連合学習のワークフロー。

3 システムモデル

3-1 ネットワークアーキテクチャ

本研究では、1つの基地局を介して1つのサーバに接続されたシングルアンテナデバイスの集合 $\mathcal{K}$ が存在するOTA連合学習システムを考える。ここで、基地局は複数のアンテナを装備している可能性があるが、ここでは簡略化のため基地局のアンテナは1本に限定する。また、基地局から d^{RIS} のところに N^{RIS} 個の要素を搭載したRISを1つ設置する。

各通信ラウンド t において、サーバはまずコホート（すなわちデバイスのサブセット） $\mathcal{K}(t) \subseteq \mathcal{K}$ をスケジュールし、スケジュールされたデバイスは指定された周波数帯域で同期して更新されたローカルモデルをアップロードする。簡潔にするため、各通信ラウンド t において送信を予定しているデバイスの数をコホートサイズ N とすると、 $|\mathcal{K}(t)| = N$ を満たす。各デバイス $k \in \mathcal{K}$ は、サーバへの送信が予定されているときはいつでも、そのローカルデータセットに基づいてローカル学習を行うことができる。デバイス k が持つローカルデータセットを $\mathcal{D}_k = \{(\mathbf{x}_{i,k}, \mathbf{y}_{i,k})\}$ とする。ただし、 $\mathbf{x}_{i,k}$ はローカルデータセット $\mathcal{D}_k$ の i 番目の特徴量、 $\mathbf{y}_{i,k}$ はそれに対応するラベルである。ここで、ローカルデータセットに重複がないことを確実にするために、 $k_1 \neq k_2$ の場合、 $\mathcal{D}_{k_1} \cap \mathcal{D}_{k_2} = \emptyset$ であるとする。OTA連合学習では、 $\mathcal{D}_k$ の学習サンプルはサーバに送信されない。その代わりに、データセットの大きさ $|\mathcal{D}_k|$ がサーバに共有される。ローカルデータセットの生データは他のデバイスやサーバに公開されないため、デバイスのデータプライバシーは保護される。また、すべてのデバイスがローカルトレーニングに使用するニューラルネットワークの構造は同一であると仮定する。

3-2 OTA 連合学習の手順

OTA連合学習システムの構成はFedAvgアルゴリズムをベースに構成されており、OTAや送信電力制御などの要素が追加されている。各通信ラウンド t において、サーバは以下の4つのステップに従ってデバイスと通信を行う。

- (1) **モデル配布**：まず、サーバは基地局を通してグローバルモデル $\mathbf{w}(t)$ を通信ラウンド t でスケジュールされたコホート $\mathcal{K}(t) \subseteq \mathcal{K}$ へ送信する。ただし、 $\mathbf{w}(0)$ はランダムなベクトルで初期化される。
- (2) **ローカル学習**：次に、 $\mathcal{K}(t)$ に含まれる各デバイスは、配布されたグローバルモデル $\mathbf{w}(t)$ と自信の持つデータセット $\mathcal{D}_k$ を用いてローカルモデル $\mathbf{w}_k(t)$ を更新する。 $\mathbf{w}_k(t)$ の更新は以下の式で行われる。

$$\mathbf{w}_k(t) = \mathbf{w}(t-1) - \eta \mathbf{g}_k(t), \quad \forall k \in \mathcal{K}(t), 1 \leq t \leq T$$

ここで η は学習率を表し、ローカル勾配 $\mathbf{g}_k(t)$ は以下の式で更新される。

$$\mathbf{g}_k(t) = \frac{1}{|\mathcal{D}_k|} \sum_{i \in \mathcal{D}_k} \nabla f(\mathbf{w}(t), \mathbf{x}_{i,k}, \mathbf{y}_{i,k}), \quad \forall k \in \mathcal{K}(t), 1 \leq t \leq T$$

ただし、 $f(\cdot, \cdot, \cdot)$ はロス関数を示す。

- (3) **モデル集約**：ローカル学習が完了すると、各デバイス $k \in \mathcal{K}(t)$ はチャネル $h_k(t)$ に基づいたさまざまな制御の後、ローカル勾配 $\tilde{\mathbf{g}}_k(t)$ をサーバへ送信する。OTA連合学習では、各デバイス k は最大送信電力 $\hat{p}_k$ を満たしながら各々の信号の大きさを揃える必要がある。デバイスは以下の式で送信信号を構成する。

$$\mathbf{s}_k(t) = a_k(t) \tilde{\mathbf{g}}_k(t), \quad \forall k \in \mathcal{K}(t), 1 \leq t \leq T$$

ここで、 $\tilde{\mathbf{g}}_k(t) = \mathbf{g}_k(t) / \|\mathbf{g}_k(t)\|$ は正規化されたローカル勾配を表す。送信振幅 $a_k(t)$ は

$$a_k(t) = \sqrt{p_k(t)} e^{j\phi_k(t)}, \quad \forall k \in \mathcal{K}(t), 1 \leq t \leq T$$

$p_k(t)$ は送信電力（最大送信電力は $\hat{p}_k$ ）、 $\phi_k(t) \in [0, 2\pi)$ は送信信号の位相である。その後、コホート内のデバイスは基地局へ同時に信号を送信し、受信信号は以下のように表される。

$$\mathbf{r}(t) = \sum_{k \in \mathcal{K}(t)} \tilde{h}_k(\boldsymbol{\theta}(t)) \mathbf{s}_k(t) + \mathbf{z}(t), \quad \forall 1 \leq t \leq T$$

ここで、 $\mathbf{z}(t) \sim \mathcal{CN}(0, \sigma^2)$ は雑音電力 σ^2 の加算性白色ガウス雑音であり、 $\tilde{h}_k(\boldsymbol{\theta}(t)) = h_k^d(t) + \mathbf{h}^T(t) \boldsymbol{\theta}(t) \mathbf{h}_k^r(t)$ は通信ラウンド t におけるデバイス k と基地局間の上りチャネルを表す。 $h_k^d(t)$ と $\mathbf{h}_k^r(t)$ はデバイス k から基地局とRISへのチャネルであり、 $\mathbf{h}(t)$ はRISから基地局へのチャネルを表す。RISの反射係数を

$$\Theta(t) = \text{diag}(e^{j\theta_1}, \dots, e^{j\theta_{N^{\text{RIS}}}}), \quad \forall 1 \leq t \leq T$$

ここで, $\theta_n \in [0, 2\pi)$ は n 番目の位相シフトを表す。

- (4) **勾配回復**：勾配集約が完了すると、受信信号はサーバへ転送される。ローカル勾配を受信信号から適切に復元するために、グローバル勾配を以下の式から得る。

$$\mathbf{g}(t) = \mathbf{r}(t)/\xi(t), \quad \forall 1 \leq t \leq T$$

ここで, $\xi(t)$ は $\tilde{h}_k(t)$ から計算されるサーバにおける勾配回復係数を表す。最後に、グローバルモデルが以下のように更新される。

$$\mathbf{w}(t) = \mathbf{w}(t-1) - \mathbf{g}(t-1), \quad \forall 1 \leq t \leq T$$

4 提案法

通常の連合学習とは異なり、最大送信電力制約や無線チャネルの品質は、OTA 連合学習システムの学習性能に大きな影響を与える。OTA 連合学習の通信ラウンド間で、デバイス-基地局間のチャネル品質は時変であり、またデバイス間でのチャネルゲインのばらつきとデバイスの最大送信電力制約により、より良いチャネルゲインを持ったデバイスからの信号が減衰してしまう。これらの問題に対処するため、本研究では動的にデバイスの送信電力、RIS 位相シフト、勾配回復スキームの共同制御を行うアルゴリズムを提案する。提案したアルゴリズムは、3つのステップから構成されており、以下に詳細を記述する。

- (1) **RIS 側の位相シフト制御**：各通信ラウンドにおいて、デバイス k に最適な RIS の反射係数を

$$\Theta_k(t) = \text{diag}(e^{j\theta_{k[1]}(t)}, \dots, e^{j\theta_{k[N]}(t)}), \quad \forall 1 \leq t \leq T$$

とする。 n 番目の位相シフト $\theta_k[n](t)$ は $\mathbf{h}[n](t)\mathbf{h}_k^H[n](t)$ を $h_k^d(t)$ に合わせるように以下の式で定義する。

$$\theta_k[n](t) = \arg(h_k^d(t)) - \arg(\mathbf{h}[n](t)) - \arg(\mathbf{h}_k^H[n](t)), \quad \forall 1 \leq t \leq T$$

そして、最適なデバイスを以下のように特定する。

$$k^*(t) = \arg \max_{k \in \mathcal{K}(t)} \sum_{l \in \mathcal{K}(t)} |\tilde{h}_l(\Theta_k(t))|, \quad \forall 1 \leq t \leq T$$

最後に、RIS の反射係数 $\{\Theta_k(t), \forall k \in \mathcal{K}(t)\}$ から $\Theta_{k^*}(t)$ を選択する。

- (2) **デバイス側の送信電力制御**：各通信ラウンド t においてコホート $\mathcal{K}(t)$ 内のデバイスは異なる最大送信電力やチャネル係数を持っている。ローカル勾配はグローバルモデルに対する変化量を表すので、デバイス間で、送信されるローカル勾配の相対的な大きさのオーダーを保持しながら適切に集約されるように、スケジュールされたデバイスの送信電力を調整する必要がある。しかし一方で、コホート全体の送信電力が不足している場合、信号がノイズのレベルまで減衰し、発散してしまう。そこで、以下のように送信電力を制御する。

$$p_k(t) = \frac{\min_{l \in \mathcal{K}(t)} \hat{P}_l |\tilde{h}_l(\Theta_{k^*}(t))|^2}{|\tilde{h}_k(\Theta_{k^*}(t))|^2}, \quad \phi_k(t) = -\arg \tilde{h}_k(\Theta_{k^*}(t)), \quad \forall k \in \mathcal{K}(t), 1 \leq t \leq T$$

- (3) **基地局側の勾配回復**：勾配の集約は、無線チャネルの品質や受信機のノイズによって大きく変動する可能性がある。集約されたローカル勾配が元の勾配より小さすぎると、OTA 連合学習プロセスの収束が遅くなる可能性がある。逆に、集約されたローカル勾配が大きすぎると、学習データの分布をうまく表現できなくなり、OTA 連合学習プロセスが発散してしまう可能性がある。したがって、ローカル勾配を元の勾配と同程度の大きさに回復することが重要であり、それによって集約されたローカル勾配をローカル学習に適切に利用できるようにする。このため、適用される送信電力とチャネル係数の平均的なアンサンブル効果を利用して、通信ラウンド t における OTA 勾配回復係数を以下のように定義する。

$$\xi(t) = \frac{1}{|\mathcal{K}(t)|} \sum_{k \in \mathcal{K}(t)} \sqrt{p_k(t)} |\tilde{h}_k(\Theta_{k^*})|, \quad \forall 1 \leq t \leq T$$

5 性能評価

5-1 パラメータ設定

以下では、すべてのシミュレーション結果で使用したデフォルトのパラメータ設定を示す。

- **システム設定**：以下の表 1 に示すように、シミュレーションで使用した OTA 連合学習システムの通信部分に関するデフォルトのパラメータ設定を示す。また、パスロスの設定について、デバイスから基地局までダイレクトリンクのパスロスは以下の式を表す。

$$PL^{D-B} = \frac{(4\pi f_c d^{D-B} / (3 \times 10^8))^2}{G^B G^D}$$

ここで、 d^{D-B} はデバイスから基地局までの距離である。また、デバイスから基地局まで RIS 経由リンクのパスロスは以下の式を表す。

$$PL^{D-R-B} = \frac{64\pi^3 (d^{R-B} d^{D-R})^2}{G^B G^D G^{RIS} L^2 d_x d_y (3 \times 10^8 / f_c)^2}$$

ここで、 d^{R-B} と d^{D-R} は RIS から基地局まで、デバイスから RIS までの距離である。

- **ニューラルネットワークのハイパーパラメータ**：各通信ラウンドにおいて、各デバイスは 3 つの全結合層からなる NN を用いてローカルモデルを更新する。なお、最適化手法には Adam、ロス関数に交差エントロピー、バッチサイズは 64、学習率には 0.0001 を用いた。
- **データセット**：シミュレーションには、機械学習分野でモデルの学習性能のベンチマークとして広く使用されている MNIST データセット[6]を用いた。MNIST データセットは 0 から 9 までの手書きの数字の大規模データベースで、60,000 の学習データと 10,000 のテストデータで構成されている。シミュレーションでは、すべてのデバイスへ MNIST データセットを振り分け、ローカルデータセットを構築した。
- **データ不均一度**：データ不均一度とは、デバイス間の学習データのラベルの分布がどの程度異なっているかを示す。学習データをデバイスへ振り分ける際、ディリクレ分布 (Dirichlet Distribution) [7]という確率分布に従って配分した。ディリクレ分布のパラメータ α はデータの不均一度を示す。 $\alpha \rightarrow \infty$ の場合、デバイス間の配分された学習データのラベル分布は独立同分布 (Identically and Independently Distributed: IID) に近づく。一方、 $\alpha \rightarrow 0$ の場合は、ラベル分布は non-IID 度合いが強まる。

表 1：OTA 連合学習の通信デフォルトパラメータ設定

パラメータ	数学記号	数値
デバイス総数	$ \mathcal{K} $	128
コホートサイズ	N	4
通信ラウンド数	T	100
基地局-デバイス間の距離 (一様分布)	–	35m～200m
基地局-RIS 間の距離	d^{RIS}	100m
各デバイスの最大送信電力	$\hat{P}_j$	23dBm
基地局のアンテナゲイン	G^B	5dBi
デバイスのアンテナゲイン	G^D	0dBi
RIS のアンテナゲイン	G^{RIS}	5dBi
基地局の雑音指数	–	5dB
周波数帯域幅	–	180kHz
ノイズ電力密度	–	-174dBm/Hz
周波数	f_c	915MHz
パスロス係数	ρ	3.76
	L	40

5-2 シミュレーション結果

図 3 では、ディリクレ分布によって MNIST データセットの学習サンプルが 128 個のデバイスにどのように

分配されるかを示している. 図 3 の縦軸は MNIST データセットの 0 から 9 までのラベルを, 横軸は 1 から 128 番目までのデバイスを示し, 緑色が濃い部分に多くの学習サンプルが振り分けられている. $\alpha = 10^{20}$ の場合, 各ラベルの学習サンプルがほぼ均等にデバイスに分布するため, データ分布はほぼ IID となる. 逆に $\alpha = 0.1$ では, 各ラベルの学習サンプルがデバイス間でより不均一になり, データ分布がより non-IID になる傾向があることがわかる.




図 3 : ディリクレ分布によるデータセット分布 (左 : $\alpha = 10^{20}$, 右 : $\alpha = 0.1$).

図 4 に, 提案法とランダム (RIS 位相を一様分布によって生成する), RIS なしとの比較結果を示す. IID, non-IID ともに提案法は高い正解率を達成している. これは, 提案法によって, RIS 要素を最適に調整できることを考えられる. そして, RIS なしは発散してしまう程度の学習性能だが, 提案法が RIS を適切に使うことで, 学習性能を大幅に向上することができる.

図 5 は, RIS の位置が提案法の学習性能にどのように影響するかを示している. RIS が基地局に近い位置にある場合 (すなわち, d^{RIS} が小さい場合), 集約されたローカル勾配が基地局の受信ノイズよりもはるかに強いいため, 提案法は良好に収束する. RIS が基地局から遠く離れた場合, 性能は低下するものの, 提案法は IID と non-IID のどちらの設定でも収束性を維持しており, これは広域での OTA 連合学習システムの実現における提案法の可能性を明らかにしている.




図 4 : 提案法の有効性の評価 (左 : $\alpha = 10^{20}$, 右 : $\alpha = 0.1$).




図 5 : d^{RIS} を変化による提案法の性能評価 (左 : $\alpha = 10^{20}$, 右 : $\alpha = 0.1$).




図 6 : RIS の要素数 N^{RIS} の変化による提案法の性能評価 (左 : $\alpha = 10^{20}$, 右 : $\alpha = 0.1$).




図 7 : 提案法の性能評価 ($\alpha = 0.1$, 左 : 正解率, 右 : エネルギー消費).

図 6 は RIS の要素数が提案法の性能にどのように影響するかを示している．基本的に，RIS の要素数が多いほど正解率は高くなるが，これは基地局での受信ノイズが，集約されたローカル勾配に比べて無視できるほど小さくなるためである．逆に RIS の要素数を小さくすると，集約されたローカル勾配の受信信号強度

は必然的に低下する．それにもかかわらず，提案法は，RIS の位相シフトを最適に制御することにより収束性を維持している．

図 7 は提案法の学習及び省エネの性能を示している．コホートサイズを増やすと正解率は高くなる．この原因は多数のデバイスが同時に送信し受信信号の強度が強まり，基地局での受信ノイズより強くて集約された勾配の品質も向上している．また，コホートサイズが増加すると，コホート同士はチャネル品質が一番弱いデバイスに合わせるため，デバイスごとのエネルギー消費が減少していることがわかる．

6 結論

本研究では OTA 連合学習システムにおける RIS 側の位相シフト，デバイス側の送信電力，基地局側の勾配回復の共同制御に関する研究を行なった．そのために，まずデバイスのチャネル係数に基づいてコホートを構築し，コホート全体の送信電力を考慮しながら，デバイス同士のチャネル係数に基づいて送信電力制御と勾配回復を実行するアルゴリズムを提案した．シミュレーションの結果，提案法は他の送信電力制御スキームを凌駕し，IID と non-IID の両方の設定において従来の FedAvg アルゴリズムに近い正解率を示した．さらに，提案法の性能は，デバイスが基地局に近い位置にある場合，またはコホートサイズが大きくなった場合にさらに向上することが分かった．本研究では，すべてのデバイス最大送信電力は同一の値としたが，今後の検討としては，デバイスごとの最大送信電力が異なる場合での送信電力制御の設計などが挙げられる．

【参考文献】

- [1] P. Voigt and A. v. d. Bussche, *The EU General Data Protection Regulation (GDPR): A Practical Guide*. Springer Int. Publ. AG, Aug. 2017.
- [2] W. Y. B. Lim, N. C. Luong, D. T. Hoang, Y. Jiao, Y.-C. Liang, Q. Yang, D. Niyato, and C. Miao, “Federated learning in mobile edge networks: A comprehensive survey,” *IEEE Commun. Surv. Tuts.*, vol. 22, no. 3, pp. 2031–2063, 2020.
- [3] B. McMahan, E. Moore, D. Ramage, S. Hampson, and B. A. y. Arcas, “Communication-efficient learning of deep networks from decentralized data,” in *Proc. AISTATS*, Apr. 2017, pp. 1273–1282.
- [4] J. Zhang and D. Tao, “Empowering things with intelligence: A survey of the progress, challenges, and opportunities in Artificial Intelligence of Things,” *IEEE Internet Things J.*, vol. 8, no. 10, pp. 7789–7817, 2021.
- [5] K. Yang, T. Jiang, Y. Shi, and Z. Ding, “Federated learning via over-the-air computation,” *IEEE Trans. Wireless Commun.*, vol. 19, no. 3, pp. 2022–2035, 2020.
- [6] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, “Gradient-based learning applied to document recognition,” *Proc. IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998.
- [7] M. Yurochkin, M. Agarwal, S. Ghosh, K. Greenewald, N. Hoang, and Y. Khazaeni, “Bayesian nonparametric federated learning of neural networks,” in *Proc. ICML*, Jun. 2019, pp. 7252–7261.

〈発 表 資 料〉

題 名	掲載誌・学会名等	発表年月
チャネル時変性に対処した OTA 連合学習におけるコホート作成	電子情報通信学会総合大会	2024 年 3 月
量子古典ハイブリッドコンピューティングによる連合学習	電子情報通信学会総合大会	2024 年 3 月
モデルポイズニング攻撃に対処する適応的連合学習に関する研究	電気関係学会関西連合大会	2023 年 11 月
Cohort-based Power Scaling and Gradient Recovery for Over-The-Air Federated Learning	IEEE Vehicular Technology Conference (VTC2023-Fall)	2023 年 10 月
Optimal Transport-based One-Shot Federated Learning for Artificial Intelligence of Things	IEEE Internet of Things Journal	2024 年 1 月
FedATM: Adaptive Trimmed Mean based Federated Learning against Model Poisoning Attacks	IEEE Vehicular Technology Conference (VTC2023-Spring)	2023 年 6 月
Joint Client Selection and Receive Beamforming for Over-The-Air Federated Learning with Energy Harvesting	IEEE Open Journal of the Communications Society	2023 年 5 月
モバイル SINET を用いた連合学習の性能に関する実証実験	電子情報通信学会総合大会	2023 年 3 月
モデルポイズニング攻撃に対処する連合学習の開発に関する研究	電子情報通信学会総合大会	2023 年 3 月
Energy Harvesting aware Client Selection for Over-The-Air Federated Learning	IEEE Global Communications Conference (GLOBECOM)	2022 年 12 月
胸部 X 線画像におけるデータ不均一度が連合学習に与える影響に関する分析	電気関係学会関西連合大会	2022 年 11 月
健康異常検知における不均一なデータへの連合学習の個別化	電子情報通信学会総合大会	2022 年 3 月