

卒業論文概要書

Summary of Bachelor's Thesis

Date of submission: 02/01/2025 (MM/DD/YYYY)

学科名 Department	情報通信学科	氏名 Name	菟場涼介	指導 教員 Advisor	渡辺 裕 ㊞
研究指導名 Research guidance	オーディオビジュアル 情報処理研究	学籍番号 Student ID number	1W212299-6		
研究題目 Title	モデルパラメータの信頼度を考慮した層ごとの Federated Learning Layer-wise Federated Learning Considering Model Parameter Reliability				

1. まえがき

Federated Learning (FL) は、複数のクライアントがデータを共有せずに、協調して機械学習モデルを訓練する分散型学習手法である。この手法は、各クライアントにおいて学習させたモデルパラメータのみをサーバで集約するため、プライバシー情報の保護を実現できる。しかしこのデータ保持の制約に起因して、クライアント間のデータ分布が不均一な場合に、モデルの学習が進みにくいことが課題となっている。そこで本研究では、この課題に対処するため、新たなモデルの集約手法を提案する。各クライアントのパラメータの情報量に基づき、それらのパラメータが共有部の更新に与える貢献度を調整する。

2. 関連研究

2.1 Personalized Federated Learning

Personalized Federated Learning (PFL) [1]は、クライアント間のデータ分布が不均一なケースに対処するための FL の手法である。PFL では、各クライアントにおけるモデルのパラメータ W_i を共有部 θ_i と専有部 w_i に分割し、共有部のみを共同で学習する。ここで、 $i \in \{1, \dots, M\}$ は各クライアントの番号、 M はクライアントの数を表す。

2.2 FedAS

FedAS[2]は、PFL における、サーバから配布された更新後の共有部と前ステップの専有部のパラメータが一貫していない問題と、クライアントごとの学習の進行度合いが不均一になる問題を解決するための手法である。FedAS では、それぞれの問題に対し、Parameter-Alignment (PA) と Client-

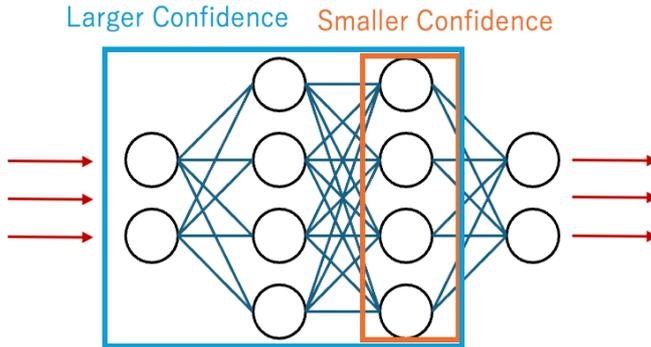


図1 提案手法概要図

Synchronization (CS) を提案している。ここで、CS とは、モデルの集約のステップにて、各クライアントのモデルのパラメータに Fisher Information Matrix (FIM) [3]を用いて重み付ける手法である。FedAS は、CS にて FIM を用いて重みをつけることで質の悪いパラメータを効率的に取り除くが、FIM の小さいパラメータの貢献度をすべての層で一律で削減してしまっているため、データ分布の差異に敏感な入力層では、質の悪いパラメータの影響が依然として大きいという問題がある。

3. 提案手法

本研究では、クライアントから収集したモデルのパラメータの信頼度を FIM で評価し、信頼度の大きさに応じて、グローバルモデルの各層ごとに、更新に用いるクライアントとその貢献度を変更する手法を提案する。提案手法のモデル構造を図1に示す。まず、各クライアント i において学習されたモデルのパラメータ θ_i の FIM のトレースの値 α_i を計算する。次に、 θ の j 層目のパラメータ θ_j の更新には、 α_i の値が大きい順に、式(1)に示される M_j

表 1 各データセットでの分類タスクにおける正解率

Dataset	Method	$\beta = 0.1$			$\beta = 0.5$			$\beta = 1.0$		
		$P = 0.2$	$P = 0.6$	$P = 1.0$	$P = 0.2$	$P = 0.6$	$P = 1.0$	$P = 0.2$	$P = 0.6$	$P = 1.0$
Cifar10	FedAS	87.02	87.40	87.24	75.75	77.13	77.55	69.60	71.47	71.69
	Ours	87.25	87.53	87.23	75.90	77.22	77.91	69.53	71.74	71.94
Cifar100	FedAS	54.19	56.69	57.54	36.20	38.38	39.75	29.07	32.20	32.40
	Ours	54.57	57.52	58.24	36.75	38.84	39.25	29.66	32.45	32.57

個のクライアントを選択する.

$$M_j = \left\lfloor \frac{j}{N_\theta} \cdot M \right\rfloor \quad (1)$$

ただし, θ の層数を N_θ , $j \in \{1, \dots, N_\theta\}$ とする. 最後に, 利用する M_j 個のクライアントの α_i を, 式(2)で示されるように正規化し, 式(3)を用いて層内のクライアントの貢献度を調整する.

$$\bar{\alpha}_{ij} = \frac{\alpha_i}{\sum_{k \in S_j} \alpha_k}, i \in S_j \quad (2)$$

$$\theta_j^{t+1} = \theta_j^t + \sum_{i \in S_j} \bar{\alpha}_{ij} \cdot (\theta_{ij}^t - \theta_j^t) \quad (3)$$

ここで, S_j は選択された j 層目の M_j 個のクライアントの集合, $\bar{\alpha}_{ij}$ は j 層目でのクライアント i の貢献度, θ_{ij} は i の j 層目のパラメータ, t はタイムステップを表す. この重み付けにより, 入力に近い層ほど信頼度の小さいパラメータの比重が小さくなる.

4. 実験

4.1 実験設定

Cifar10[4], Cifar100[4]データセットを用いた画像分類タスクにて提案手法を評価する. データの分割には, パラメータ β に従うディリクレ分布を用いる. β は小さいほどデータの分布の偏りが大きくなる. モデルには4層のCNNを用いる. 最初の3層を共有部, 最終層を専有部とする. Cifar10では出力層を10, Cifar100では出力層を100に設定する.

クライアント数 M は20, グローバルエポック数は40, ローカルエポック数は5と設定する. また, クライアントのうち, 1回の共有部の更新に参加する割合を P として導入し, P に応じて参加するクライアントをランダムに決定する.

4.2 実験結果

Cifar10とCifar100の分類タスクにおいて, $\beta \in \{0.1, 0.5, 1.0\}$, $P \in \{0.2, 0.6, 1.0\}$ に設定したときの, 従来手法であるFedASと提案手法の正解率の値を表1に示す. 表1より, 多くのケースで, 本手法が従来手法よりも有効であるとわかる. また, Cifar10に比べ, Cifar100での精度の上昇幅が大きいことがわかる. この原因の1つとして, クラス数が多いCifar100ではデータ分布の差異が大きく, それに伴い質の低いパラメータが多く含まれていたが, 本手法では入力層付近において質の悪いパラメータを効果的に除去できたことが考えられる.

5. むすび

本研究では, モデルパラメータのFIMを信頼度として評価し, 信頼度に応じてグローバルモデルの更新に関与する度合いを決定する手法を提案した. Cifar10とCifar100での分類タスクでの実験の結果, 従来手法に比べ, 提案手法が分類精度を改善することを示した.

参考文献

- [1] Z. Qu *et al.*, "How to Prevent the Poor Performance Clients for Personalized Federated Learning?," Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023, pp. 12167-12176.
- [2] X. Yang *et al.*, "FedAS: Bridging Inconsistency in Personalized Federated Learning," Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024, pp. 11986-11995.
- [3] S. Amari, "Natural Gradient Works Efficiently in Learning," Neural Computation, vol. 10, no. 2, pp. 251-276.
- [4] A. Krizhevsky, "Learning multiple layers of features from tiny images," 2009.

2024 年度 卒業論文

モデルパラメータの信頼度を考慮した層ごとの Federated
Learning
Layer-wise Federated Learning Considering Model Parameter
Reliability

指導教員 渡辺裕 教授

提出日：2025 年 2 月 1 日

早稲田大学 基幹理工学部 情報通信学科

1W212299-6

菟場涼介

目次

第 1 章	序章	1
1.1	研究背景	1
1.2	研究目的	1
1.3	むすび	2
第 2 章	関連研究	3
2.1	まえがき	3
2.2	Federated Learning	3
2.3	Personalized Federated Learning	4
2.4	FedAS	5
2.5	むすび	6
第 3 章	提案手法	7
3.1	まえがき	7
3.2	提案手法	7
3.3	むすび	8
第 4 章	実験結果と考察	9
4.1	まえがき	9
4.2	実験設定	9
4.2.1	データセット	9
4.2.2	共有部と専有部の分割	9
4.2.3	評価指標	10
4.2.4	実験パラメータ設定	10
4.3	実験結果	11
4.4	考察	12
4.5	むすび	12
第 5 章	結論と今後の課題	13
5.1	結論	13

5.2 今後の課題	13
謝辞	14
参考文献	15
表一覧	17
図一覧	18
研究業績	19

第1章 序章

1.1 研究背景

近年、機械学習の需要が急速に拡大している。機械学習はさまざまな産業分野で導入が進んでおり、人の代わりとなる労働力としての活躍が期待されている[1]。

現在使われている多くの機械学習モデルは、大量の学習データを必要とする。しかし今日では、プライバシーを保護するための法律が厳格化しており、企業や組織は自身の保持する個人情報などを学習データとして使用することが困難になっている[2]。また、診療データなどのセンシティブな情報を取り扱う場合には、プライバシー保護の法律上は問題がなくとも、データ保有者がデータの収集・利用を拒否する場合があります、さらに学習データの収集が困難となる。

また、比較的規模の小さい企業や組織では取得できるデータの量に限りがあり、十分な量の学習データを用意できないなどの問題がある。

以上のことから、プライバシーポリシーに抵触しないように学習できる仕組みが必要となっている。

1.2 研究目的

プライバシーの保護に優れた学習アルゴリズムとして、**Federated Learning (FL)** [3, 4]が提案されている。FLはデータを集約することなく、複数の学習参加者（クライアント）でモデルを学習する手法である。この手法は、データを外部に共有せず、個々のクライアントで各々の保持するデータでのみ学習するため、個人情報などのセンシティブなデータも学習に用いやすいというメリットがある。一方、データを一箇所に集約しないことにより、各クライアントが保持するデータの分布がわからないという問題点がある。データを一箇所に集約する機械学習手法では、データの分布に偏りがあった場合、データ拡張、ダウンサンプリングなどで対処できる。しかし、FLではクライアントのデータの分布を知ることができないため、データ拡張などを用いることができず、結果として偏ったデータの分布で学習を行うこととなる。

本研究では、データの分布が偏った状態での精度の向上を目的として、新たなモデルの集約手法を提案する。本手法は、各クライアントから集められたモデルを **Fisher Information Matrix (FIM)** [5]を用いて評価し、FIMの値の大きさに応じてグローバルモデルの更新への、それらのパラメータの貢献度合いを層ごとに変更する。Cifar10 [6]とCifar100 [6]を用いた分類タスクでの実験により、本手法が特定のケースで従来手法よりも有用であることを示す。

1.3 むすび

本論文の構成を以下に示す.

第1章は本章であり, 本論文の研究背景, 研究目的について述べる.

第2章では本研究で用いる関連技術について述べる.

第3章では本研究で提案する球審視点映像による判定手法について述べる.

第4章では実験の結果及び考察について述べる.

第5章では本論文の結論及び今後の課題について述べる.

第2章 関連研究

2.1 まえがき

本章では、関連研究について説明する。まずプライバシー保護に優れた学習アルゴリズムである FL について説明する。次に FL の派生技術である **Personalized Federated Learning (PFL)** [7, 8] を説明する。最後に FIM を PFL に用いた学習手法である FedAS [9] について説明する。

2.2 Federated Learning

Federated Learning (FL) は、分散環境における複数のクライアントが、各自のデータをローカルに保持するという制約の元で協調しながら機械学習モデルを学習するフレームワークである。FL では、各クライアントのローカルにのみデータを保持するという制約上、プライバシーの保護に優れており、医療分野などセンシティブな情報を取り扱う分野で特に注目されている。

ここでは FL の基本プロセスを説明する。FL でのグローバルモデルの更更新手順は以下の 5 ステップに分けられ、この一連の更更新手順をラウンドと呼ぶ。学習時は、指定のラウンド数だけ、以下のステップを繰り返す。

[1] クライアントの選択

サーバは、学習に参加しているクライアントのうち、今回のラウンドに参加するクライアントを選択する。

[2] モデルの配布

サーバは、[1]で選択されたクライアントに対して、最新のグローバルモデルのパラメータを配布する。ここで、グローバルモデルとは、FL において、すべてのクライアントで共同して学習したいモデルのことを指す。

[3] ローカルでの学習

各クライアントは自身が保持するデータを用いて、[2]で配布されたモデルを更更新する。このステップで更更新されたモデルのことをローカルモデルと呼ぶ。

[4] モデルの収集

サーバは、各クライアントが[3]で学習したローカルモデルを収集する。

[5] モデルの集約・更更新

[4]で収集したローカルモデルを集約し、グローバルモデルを更更新する。

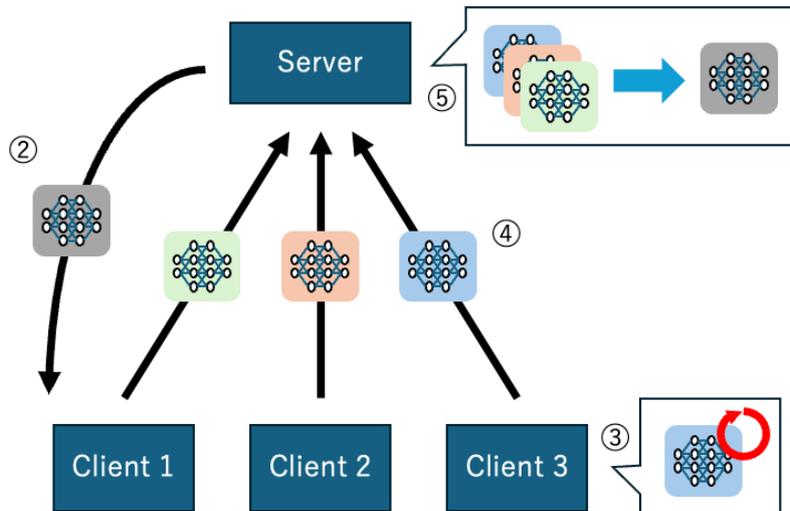


図 2.1 Federated Learning 概要図

2.3 Personalized Federated Learning

Personalized Federated Learning (PFL) は、クライアント間のデータ分布が不均一なケースに対処するための FL の手法である。従来の FL ではモデル全体のパラメータを共有し学習するが、PFL ではモデルの一部を共有せず、専有部として学習する。

まず、各クライアントにおけるモデルのパラメータ W_i を θ と w_i に分割する。 θ は共有部、 w_i は専有部、 $i \in \{1, \dots, M\}$ は各クライアントの番号、 M はクライアントの数を表す。 PFL の学習ステップは以下の 2 つに分けられる。

- ・ **クライアントの学習** : サーバから共有部のパラメータ θ^t を受信し、クライアント i のパラメータを $W_i^t = (\theta^t, w_i^t)$ で初期化する。ローカルで指定のエポック数 E_{local} 学習し、更新されたパラメータ $W_i^{t+1} = (\theta_i^t, w_i^{t+1})$ を得る。
- ・ **モデルの集約** : 各クライアントでの学習前後のパラメータの差分 $\Delta\theta_i^t = \theta_i^t - \theta^t$ を集約し、新しい共有部のパラメータ θ^{t+1} を作成する。そして、再びクライアントに配布し、クライアントで学習させる。

ただし、 t は $t \in \{1, \dots, E_{global}\}$ 番目の学習ラウンドを表し、 E_{global} は共有部を更新する回数を表す。

以上により、クライアント間のデータ分布の差異による学習進行の阻害を軽減できる。

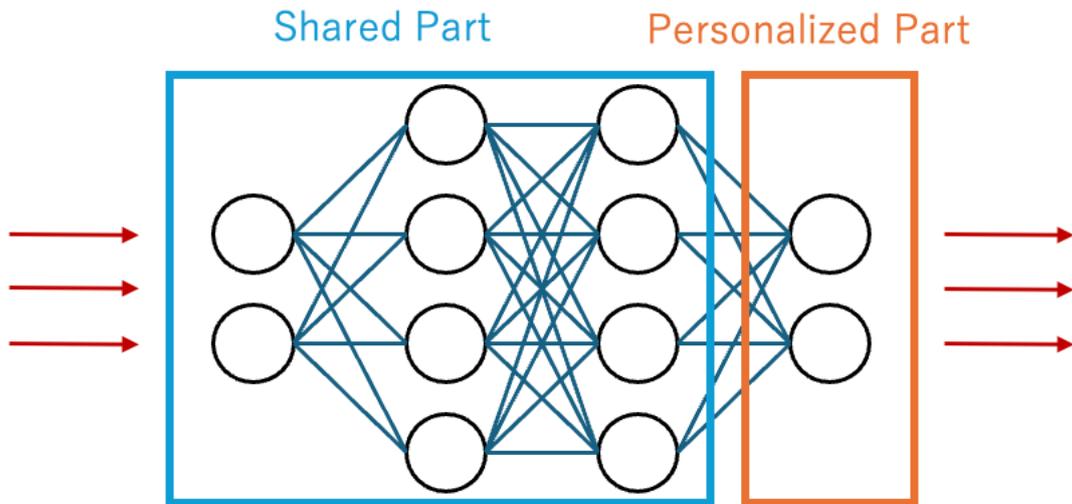


図 2.2 Personalized Federated Learning 概要図

2.4 FedAS

FedAS は PFL におけるクライアント内とクライアント間の不整合を解決するための手法である。クライアント内の不整合とは、サーバから配布された更新後の共有部のパラメータ θ^{t+1} と学習前の専有部のパラメータ w_i^t が一貫していない問題を指す。クライアント間の不整合とは、クライアントごとの学習の進行度合いが不均一な状態を指す。

FedAS では、上記の問題への対処法として、Parameter-Alignment (PA) と Client-Synchronization (CS) を提案している。PA はクライアントの学習ステップの最初に、新しく配布された共有部のパラメータ θ^{t+1} を前ステップでの共有部のパラメータ θ^t に近づけることで、クライアント内の不整合に対処する手法である。CS はモデルの集約のステップにて、各クライアントのモデルのパラメータに FIM を用いて重み付けることで、未学習のパラメータによる学習進行の阻害を軽減し、クライアント間の不整合に対処する手法である。

CS に用いられる FIM は、統計モデルにおいて、真の確率分布のパラメータに関してどれだけ情報を保持しているかを測る指標である。未学習のモデルのパラメータの FIM は小さく、十分に学習されているパラメータの FIM は大きい傾向がある。また、FIM のトレースの値 (t-FIM) はクライアントモデルが学習した情報量を定量化し、パラメータの重要性を示す。

2.5 むすび

本章では, 本研究の属する分野である FL と PFL, そして PFL の問題点に対処する手法である FedAS に関して説明した.

第3章 提案手法

3.1 まえがき

本章では、モデルの信頼度の大きさに応じて、グローバルモデルの各層ごとに、更新に用いるクライアントとその貢献度を変更する手法を提案する。信頼度の評価には FIM を用いる。

3.2 提案手法

FedAS では、学習の進行を妨げる質の悪いパラメータを、FIM を用いて効率的に学習から取り除くが、FIM の小さいパラメータの貢献度をすべての層で一律で削減してしまっているため、データ分布の差異に敏感な入力層では、質の悪いパラメータの影響が依然として大きい。そこで本稿では、クライアントから収集したモデルのパラメータ $\Delta\theta_i^t$ の信頼度を FIM で評価し、信頼度の大きさに応じて、グローバルモデルの各層ごとに、更新に用いるクライアントとその貢献度を変更する。

まず、各クライアント i において、学習終了時点で FIM を計算し、その FIM のトレースの値 α_i をを得る。 θ の j 層目のパラメータ θ_j の更新には、 α_i の値が大きい順に、式(1)に示される M_j 個のクライアントを選択する。

$$M_j = \left\lfloor \frac{j}{N_\theta} \cdot M \right\rfloor. \quad (1)$$

ただし、 θ の層数を N_θ 、 $j \in \{1, \dots, N_\theta\}$ とする。次に、利用する M_j 個のクライアントの α_i を、式(2)で示されるように正規化し、式(3)を用いて層内のクライアントの貢献度を調整する。

$$\bar{\alpha}_{ij} = \frac{\alpha_i}{\sum_{k \in S_j} \alpha_k}, i \in S_j. \quad (2)$$

$$\theta_j^{t+1} = \theta_j^t + \sum_{i \in S_j} \bar{\alpha}_{ij} \cdot \Delta\theta_{ij}^t. \quad (3)$$

ここで、 S_j は選択された j 層目の M_j 個のクライアントの集合、 $\bar{\alpha}_{ij}$ は j 層目でのクライアント i の貢献度、 θ_{ij} はクライアント i の j 層目のパラメータを表す。この重み付けによって、入力に近い層ほど、信頼度の小さいパラメータの比重が小さくなる。

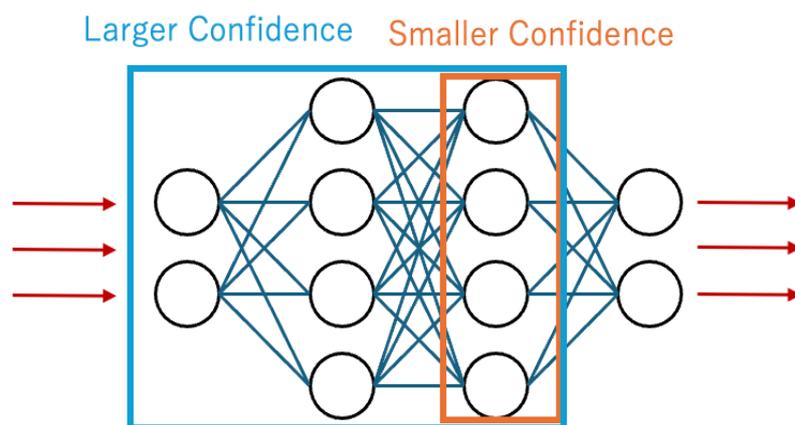


図 3.1 提案手法概要図

3.3 むすび

本章では、本研究で提案する、モデルの信頼度に応じて、層ごとにパラメータ更新への貢献度を変更する手法について述べた。

第4章 実験結果と考察

4.1 まえがき

本章では, 提案手法に基づく実験の概要, 結果及び考察について述べる. 実験では, Cifar10 と Cifar100 のデータセットにおける分類タスクで精度を比較した.

4.2 実験設定

4.2.1 データセット

本実験では, データセットとして Cifar10 と Cifar100 を用いた.

Cifar10 は画像サイズ 32×32 の画像 60,000 枚で構成されており, 10 クラスに均等に分類されている. このうち 50,000 枚が学習用, 10,000 枚がテスト用データとして使用される.

同様に, Cifar100 は画像サイズ 32×32 の画像 60,000 枚で構成されており, 100 クラスに均等に分類されている. このうち 50,000 枚が学習用, 10,000 枚がテスト用データとして使用される.

Cifar10 と Cifar100 を提供しているホームページ(<https://www.cs.toronto.edu/~kriz/cifar.html>)にて, 「Learning Multiple Layers of Features from Tiny Images, Alex Krizhevsky, 2009.」を引用することで, 実験での使用および論文での掲載を許可すると記載されていたため, [6]を引用し, 実験に用いた.

どちらのデータセットにおいても, ディリクレ分布[10]によるデータの分割を行なった. 本実験では, ディリクレ分布のデータの偏り具合を調整するパラメータ β を導入し, データの分布の偏り具合を変更して実験を行なった. パラメータ β は小さいほどデータの分布の偏りが大きくなる.

4.2.2 共有部と専有部の分割

本実験では, 実験に用いる 4 層の CNN ネットワークのうち, 入力側から 3 層を共有部とし, 最後の 1 層を専有部として分割する.

また, 図 4.1 の中で用いられている各ブロックの構造を図 4.2 に示す. Cifar10 では Head の出力層を 10 に, Cifar100 では Head の出力層を 100 に設定する.

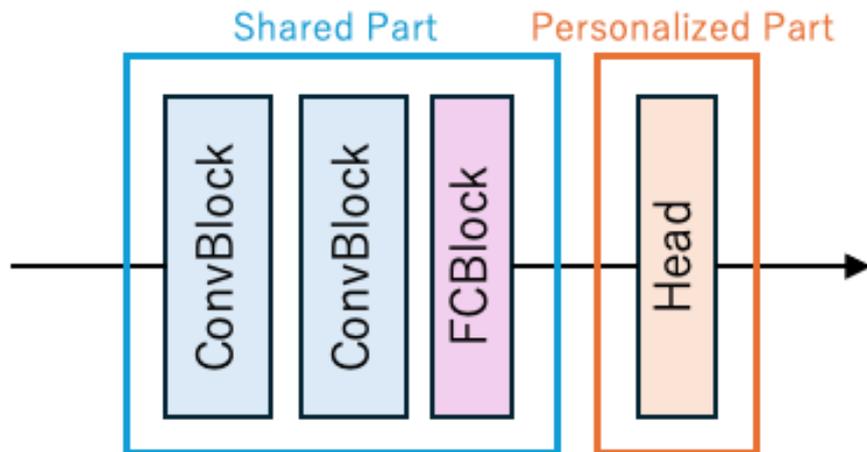


図 4.1 共有部と専有部の分割

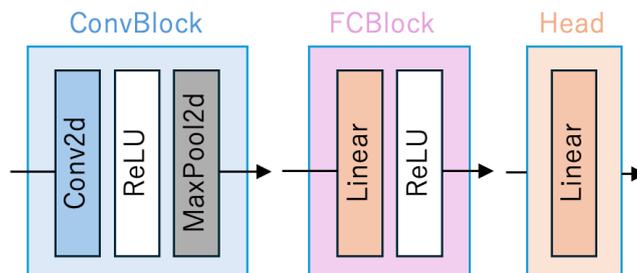


図 4.2 各 Block の構造

4.2.3 評価指標

本実験では、評価指標として「local_acc」、 「global_acc」を採用する。local_acc は、各クライアントのモデルを用い、各々のクライアントが保持する検証用データに対する分類タスクの正解率の平均値とする。global_acc は、各クライアントのモデルを用い、全クライアントの検証用データに対する分類タスクの正解率の平均値とする。

4.2.4 実験パラメータ設定

クライアント数 M は 20、グローバルエポック数 E_{global} は 40、ローカルエポック数 E_{local} は 5、バッチサイズは 16 と設定する。オプティマイザには SGD を用い、学習率は $5e-3$ 、学習率減衰は $1e-3$ とする。また、クライアントのうち、1 回の共有部の更新に参加する割合を P として導入し、 P に応じて参加するクライアントをランダムに決定する。更に、クライアント内の不整合に対処するため、FedAS の PA を用いる。

4.3 実験結果

本実験では、本提案手法の比較対象として、FL を用いずパラメータを共有しない方法での学習（以下 woFL と記述）と、PFL を用いた従来手法である FedAS を実験に用いた。

データセットは Cifar10 と Cifar100 を使用し、 $\beta \in \{0.1, 0.5, 1.0\}$, $P \in \{0.2, 0.6, 1.0\}$ と設定したときの、分類タスクにおける woFL, FedAS, 本提案手法の精度を検証した。

各条件における Cifar10, Cifar100 の local_acc を表 4.1, 表 4.2 にそれぞれ示す。また、各条件における Cifar10, Cifar100 の global_acc を表 4.3, 表 4.4 にそれぞれ示す。

表 4.1, 表 4.2 より、ほとんどのケースにおいて、本提案手法の local_acc が一番高いことがわかる。加えて、Cifar10 に比べ、Cifar100 での local_acc の上昇幅が大きいことがわかる。

また、表 4.3, 表 4.4 より、ほとんどのケースにおいて、本提案手法の global_acc が一番高いことがわかる。

表 4.1 Cifar10 の分類タスクにおける local_acc の比較

Method	$\beta = 0.1$			$\beta = 0.5$			$\beta = 1.0$		
	$P = 0.2$	$P = 0.6$	$P = 1.0$	$P = 0.2$	$P = 0.6$	$P = 1.0$	$P = 0.2$	$P = 0.6$	$P = 1.0$
woFL	83.78	84.97	85.25	67.68	69.65	70.55	58.35	61.35	61.59
FedAS	87.02	87.40	87.24	75.75	77.13	77.55	69.60	71.47	71.69
Ours	87.25	87.53	87.23	75.90	77.22	77.91	69.53	71.74	71.94

表 4.2 Cifar100 の分類タスクにおける local_acc の比較

Method	$\beta = 0.1$			$\beta = 0.5$			$\beta = 1.0$		
	$P = 0.2$	$P = 0.6$	$P = 1.0$	$P = 0.2$	$P = 0.6$	$P = 1.0$	$P = 0.2$	$P = 0.6$	$P = 1.0$
woFL	48.54	51.90	51.29	26.89	21.28	19.53	19.40	14.85	8.54
FedAS	54.19	56.69	57.54	36.20	38.38	39.75	29.07	32.20	32.40
Ours	54.57	57.52	58.24	36.75	38.84	39.25	29.66	32.45	32.57

表 4.3 Cifar10 の分類タスクにおける global_acc の比較

Method	$\beta = 0.1$			$\beta = 0.5$			$\beta = 1.0$		
	$P = 0.2$	$P = 0.6$	$P = 1.0$	$P = 0.2$	$P = 0.6$	$P = 1.0$	$P = 0.2$	$P = 0.6$	$P = 1.0$
woFL	21.98	24.70	24.80	30.97	35.70	35.84	35.40	41.14	41.25
FedAS	26.97	27.56	27.51	42.22	43.95	44.35	49.94	52.41	53.16
Ours	27.14	27.60	27.54	42.62	44.25	44.65	50.03	52.75	53.58

表 4.4 Cifar100 の分類タスクにおける global_acc の比較

Method	$\beta = 0.1$			$\beta = 0.5$			$\beta = 1.0$		
	$P = 0.2$	$P = 0.6$	$P = 1.0$	$P = 0.2$	$P = 0.6$	$P = 1.0$	$P = 0.2$	$P = 0.6$	$P = 1.0$
woFL	6.64	7.95	7.95	8.97	7.74	7.01	9.11	7.33	4.63
FedAS	8.49	9.36	9.48	14.52	16.19	16.97	16.63	18.75	19.31
Ours	8.60	9.56	9.70	14.80	16.38	16.75	17.06	19.01	19.43

4.4 考察

表 4.1, 表 4.2, 表 4.3, 表 4.4 より, 本提案手法によって, local_acc と global_acc の両方で精度を改善した. 精度改善の要因の一つとして, 未学習のパラメータやほかのクライアントとは異なるデータ分布を持つクライアントで学習されたパラメータなど, 比較的 FIM が小さいモデルのパラメータが学習に関わる層を限定したことによって, 十分に学習されたモデルのパラメータの貢献度を高められたことが挙げられる. また, Cifar10 に比べ, Cifar100 での精度の上昇幅が大きいことがわかる. この要因の一つとして, クラス数が多い Cifar100 ではデータ分布の差異が大きく, それに伴い質の低いパラメータが多く含まれていたが, 本手法では, 入力層付近において質の悪いパラメータを効果的に除去できたことが考えられる.

4.5 むすび

本章では, Cifar10 と Cifar100 での分類タスクの実験を通して, 本提案手法の有効性を確認した.

第5章 結論と今後の課題

5.1 結論

本研究では、モデルパのラメータの t -FIM を信頼度として評価し、その値に応じてグローバルモデルの更新に関与する度合いを層ごとに決定する手法を提案した。

提案手法では、データ分布の差異に敏感な入力層付近の更新から信頼度の小さいモデルのパラメータを除外する処理を加えた。

実験では、Cifar10 と Cifar100 での分類タスクを行い、従来手法に比べて、本提案手法が分類精度を改善することを示した。

5.2 今後の課題

本提案手法では、モデルの t -FIM の大きさを信頼度として評価し、信頼度の大きさに応じて、グローバルモデルの各層ごとに、更新に用いるクライアントとその貢献度を変更した。

しかし、本手法では、層ごとの更新に用いるクライアントとその貢献度をモデル全体の信頼度で決定しており、モデルの層ごとの信頼度によって決定していない。今後、さらなる精度の改善のために、モデルの層ごとの信頼度を計算し、その値に応じて更新に用いる層を決定する必要がある。

謝辞

本研究の遂行にあたり，多大なるご指導とご助言を賜りました渡辺裕教授に心よりお礼申し上げます。

また，日頃より研究に関する有益な助言や建設的なご指摘をいただいた研究室の皆様に深くお礼申し上げます。

最後に，これまでの私の成長を支え，精神的および経済的に多大な支援を与えてくださった家族に心よりお礼申し上げます。

参考文献

- [1] 総務省, “令和 6 年度版情報通信白書 : 第 I 部特集②進化するデジタルテクノロジーとの共生”, 総務省, (最終閲覧日 : 2025 年 1 月 13 日), <https://www.soumu.go.jp/johotsusintokei/whitepaper/ja/r06/html/nd151120.html>.
- [2] 個人情報保護委員会, “EU (外国制度) : GDPR (General Data Protection Regulation : 一般データ保護規則)”, (最終閲覧日 : 2025 年 1 月 13 日), <https://www.ppc.go.jp/enforcement/infoprovision/EU/>.
- [3] B. McMahan, E. Moore, D. Ramage, S. Hampson and B. A. Arcas, “Communication-Efficient Learning of Deep Networks from Decentralized Data,” Proceedings of the 20th International Conference on Artificial Intelligence and Statistics (PMLR), vol. 54, 1273-1282, Aug. 2017.
- [4] Q. Li, Z. Wen, Z. Wu, S. Hu, N. Wang, Y. Li, X. Liu and B. He, "A Survey on Federated Learning Systems: Vision, Hype and Reality for Data Privacy and Protection," IEEE Transactions on Knowledge & Data Engineering, vol. 35, no. 04, pp. 3347-3366, Apr. 2023.
- [5] S. Amari, “Natural Gradient Works Efficiently in Learning,” Neural Computation, vol. 10, no. 2, pp. 251-276, Feb. 1998.
- [6] A. Krizhevsky, “Learning multiple layers of features from tiny images.” 2009, (最終閲覧日 : 2025 年 1 月 15 日), <https://www.cs.toronto.edu/~kriz/learning-features-2009-TR.pdf>
- [7] Z. Qu, X. Li, X. Han, R. Duan, C. Shen and L. Chen, "How to Prevent the Poor Performance Clients for Personalized Federated Learning?" IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), pp. 12167-12176, Jun. 2023.
- [8] V. Kulkarni, M. Kulkarni and A. Pant, "Survey of Personalization Techniques for Federated Learning," 2020 Fourth World Conference on Smart Trends in Systems, Security and Sustainability (WorldS4), pp. 794-797, Jul. 2020.
- [9] X. Yang, W. Huang and M. Ye, "FedAS: Bridging Inconsistency in Personalized Federated Learning," IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), pp. 11986-11995, Jun. 2024.

- [10] T. Lin, L. Kong, S. U. Stich, M. Jaggi, “Ensemble Distillation for Robust Model Fusion in Federated Learning,” Proceedings of the 34th International Conference on Neural Information Processing Systems (NIPS '20), article 198, pp. 2351–2363, Dec. 2020.

表一覧

表 4.1	Cifar10 の分類タスクにおける local_acc の比較.....	11
表 4.2	Cifar100 の分類タスクにおける local_acc の比較.....	11
表 4.3	Cifar10 の分類タスクにおける global_acc の比較.....	11
表 4.4	Cifar100 の分類タスクにおける global_acc の比較.....	12

図一覧

図 2.1 Federated Learning 概要図.....	4
図 2.2 Personalized Federated Learning 概要図.....	5
図 3.1 提案手法概要図.....	8
図 4.1 共有部と専有部の分割.....	10
図 4.2 各 Block の構造.....	10

研究業績

- [1] 菟場涼介, 渡辺裕, “モデルのパラメータの信頼度を考慮した Federated Learning (Federated Learning Considering the Confidence Score of Model Parameters),” 2025 年 情報処理学会全国大会, Mar. 2025. (発表予定)