

一般口演 | 第40回医療情報学連合大会（第21回日本医療情報学会学術大会） | 一般口演

## 一般口演7 医療支援

2020年11月19日(木) 16:20 ~ 18:00 D会場 (コンgresセンター4階・43~44会議室)

### [2-D-3-01] 医療データの特徴を考慮した多施設間 Federated Learning の設計

\*馬 雲蔚<sup>1</sup>、岡本 和也<sup>1,2</sup>、杉山 治<sup>3</sup>、山本 豪志朗<sup>2</sup>、佐々木 博史<sup>2</sup>、南部 雅幸<sup>2</sup>、黒田 知宏<sup>1,2</sup> (1. 京都大学大学院情報学研究科, 2. 京都大学医学部附属病院, 3. 京都大学大学院医学研究科)

\*Yunwei Ma<sup>1</sup>, Kazuya Okamoto<sup>1,2</sup>, Osamu Sugiyama<sup>3</sup>, Goshiro Yamamoto<sup>2</sup>, Hiroshi Sasaki<sup>2</sup>, Masayuki Nambu<sup>2</sup>, Tomohiro Kuroda<sup>1,2</sup> (1. 京都大学大学院情報学研究科, 2. 京都大学医学部附属病院, 3. 京都大学大学院医学研究科)

キーワード : Federated Learning, Deep Learning, Medical Data Characteristics

深層学習において学習データの量を確保するために多施設の医療データを学習データとして利用することが望まれるが、患者プライバシーの問題のため医療データを多施設間で共有することは難しい。そのため、医療データの代わりに学習モデルのみを共有する分散学習手法を用いることが検討されている。しかし、施設間で蓄積された医療データ数や、施設ごとの疾病状態を表すクラス間のデータ数に偏りがあるため、従来の分散学習手法では十分な学習を行うことができない。

本研究では、既存の Federated Learning 技術に基づき、施設間のデータ数に偏りがあり、さらに、クラス間のデータ数に偏りがある状況においてもロバストな分散学習手法を提案する。

Federated Learning とは、各施設でデータの処理・モデル学習を行い、そのモデルを集めることでより洗練されたモデルを作成・再配布する分散学習手法である。本研究では、クラス間のデータ数の偏り、施設間のデータ数の偏りを解決する技術を、勾配の更新式で統合することにより、2つの「偏り」を同時に考慮しながら学習を行う Federated Learning の手法を設計した。具体的には、勾配の更新式にある学習率  $\eta$  を施設間のデータ数の偏り、同じ施設内のラベルごとのデータ数の偏りに合わせた動的な更新を試みた。また、各施設における学習の進み具合（lossの低下率）によっても  $\eta$  を変化させた。

提案手法は、公開されている糖尿病眼底写真のデータセットを用いて検証した。糖尿病眼底写真のデータセットを施設数で分割し、施設間でデータ数を、施設内ではクラス間のデータ数に偏りを持たせることで、本研究が扱う課題が再現された実験環境を作成し、提案手法によって学習精度や、学習効率がどのように変化するかを調べた。

# 医療データの特徴を考慮した多施設間 Federated Learning の設計

MA YUNWEI\*1、岡本和也\*1,2、杉山治\*3、山本豪志朗\*2、

佐々木博史\*2、南部雅幸\*2、黒田知宏\*1,2

\*1 京都大学大学院情報学研究科、\*2 京都大学医学部附属病院

\*3 京都大学大学院医学研究科

## Design of Multi-institutional Federated Learning Considering Medical Data Characteristics

Yunwei Ma\*1, Kazuya Okamoto\*1,2, Osamu Sugiyama\*3, Goshiro Yamamoto\*2,

Hiroshi Sasaki\*2, Masayuki Nambu\*2, Tomohiro Kuroda\*1,2

\*1 Graduate School of Informatics, Kyoto University, \*2 Kyoto University Hospital,

\*3 Graduate School of Medicine, Kyoto University

Recent years, the deep learning technology has been introduced in the medical field. In order to train a better classifier with deep learning, usually larger medical data among medical facilities were required. However, it is difficult to collect a large amount of data in one place due to the privacy concerns of the patients. Instead, the Federated Learning has been applied in this field. Since the Federated Learning method learns by exchanging only weights of training models among facilities, the facilities do not need to share their data. However, researches using the method did not consider complicated provisional conditions similar to the real environments. In this research, based on the existing Federated Learning methodologies, we proposed a distributed learning method which is robust neither the numbers of data among facilities nor the numbers of data among classes are uneven. By assuming an actual environment, we conducted an experiment using diabetic retinopathy image data published on the Internet. As a result, the effectiveness of the proposed method was shown in the experiment. In the future, we would like to verify with more facilities and other medical data.

Keywords: Federated Learning, Deep Learning, Privacy

### 1. 緒論

2012年、深層学習の有用性を示す出来事が起きた。画像認識コンテスト ILSVRC (ImageNet Large Scale Visual Recognition Challenge) において、Krizhevskyらのグループが深層学習を利用した AlexNet という手法を用いて1年前の優勝記録の誤り率を25.7%から15.3%へと4割も削減し圧勝した<sup>1)</sup>。以来、一般画像認識において深層学習が注目を集めている。さらに、医療分野でも深層学習の応用研究が進み、Yangらによると、図1に示すように2015年から2019年にかけて深層学習を用いた医用画像の分析研究が増えている<sup>2)</sup>。

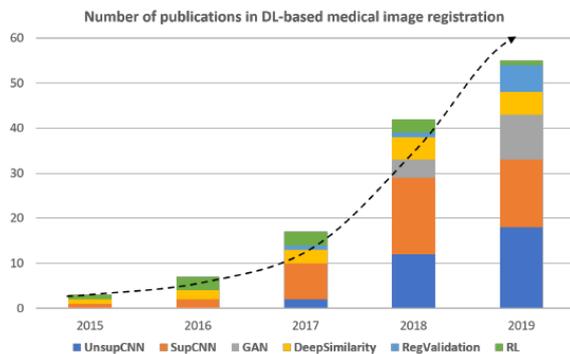


図1 深層学習を用いて医用画像の分析を行った出版物の数<sup>2)</sup>

Yangらが調べた2015年から2019年の間に行われた深層学習を用いた医用画像の分析研究150件の出版物の内訳。

医療分野においても深層学習を用いた応用研究が増加している理由として、いくつかのメリットが挙げられる。従来では発症してからしか診断・治療の行えなかった疾患であっても、高精度な予測が可能となることによって、発症前に患者が診断・治療を受けられるようになる。また、十分な効果が見込める治療薬がない疾患に対する画期的な医薬品等、新たな治療方法や診断方法の創出が期待できる。

深層学習は、高い学習精度を達成するために大量の構造化された訓練データを用い、その結果として一般化とロバスト性を増加させる。しかしながら、医療データの場合、大量の訓練データを集めることは簡単ではなく、特にまれな疾患の場合には訓練データ数は小さくなる傾向がある<sup>3)</sup>。また、倫理上、あるいは、規制上の問題により、医療データを各医療施設内から出せないことが多く、複数の医療施設で医療データを共有することは難しい<sup>4)</sup>。したがって、一般的には医療分野での深層学習を用いた研究では、小さなデータセットで深層学習の学習モデルを訓練することが多く、医療データを使った深層学習で得られる学習精度を上げるのは他の分野に比べて難しい。

学習精度を向上させるため、複数の医療施設で医療データを共有する代わりに学習モデルを共有する分散学習手法を用いることが検討されている。代表的な分散深層学習手法としては Federated Learning<sup>5)</sup>があり、その他にも差分プライバシー<sup>6)</sup>、準同型暗号化<sup>7)</sup>、Split Learning<sup>8)</sup>、Cyclical Weight Transfer<sup>9)</sup>といった手法が存在する。これらの分散深層学習手法を使うことにより、複数の医療施設間で医療データを共有することなく、複数の医療施設の保有する医療データを用いた学習モデルの訓練が可能となる。しかし、各医療施設の保

有する医療データはデータ数の偏りやクラス間のデータ数に偏りがあることが一般的であり、これらの偏りに対する考慮が必要と考えられる。

本研究では、医療施設間のデータ数に偏りがあり、クラス間のデータ数に偏りがある状況においてもロバストな分散学習が行える Federated Learning にもとづいた手法を提案する。

## 2. 関連研究

分散学習手法に関する大半の研究は通信量の最適化やプライバシーの保護に注目している<sup>10)</sup>。Taoらの研究では、通信の効率化を図って、計算量を減少できる eSGD という手法を提案した<sup>11)</sup>。また、McMahanらは、アップロードの通信量を減らす2種類の提案手法を検証した<sup>12)</sup>。Bhagojiらは、悪意あるパラメータ共有によってモデル汚染ができることを証明し、既存のアルゴリズムでは完全に汚染を防ぐことは難しいと問題提起した<sup>13)</sup>。

本研究のように施設間の訓練データ数の偏りや各施設内でのクラス間の訓練データ数の偏りに注目した研究は多くない。Abhijitらはサーバを持たないピアツーピア環境の Federated Learning として BrainTorrent を提案し、評価実験において施設数を変化させたが<sup>14)</sup>、訓練データ数の偏りには着目していない。Balachandarらは、Federated Learning とは別の分散学習手法である Cyclical Weight Transfer (CWT) を用いて、施設間の医療データ数と疾病状態を表すクラス間のデータ数それぞれの違いに対して最適化された既存手法を提案した<sup>15)</sup>。CWT は各施設が逐次的に学習を行う分散学習手法であり、医療のためのデータプライバシー保護分散学習手法として Chang らによって提案された<sup>9)</sup>。しかし、癌細胞の影響を受けた組織から健康な脳組織を識別する Micah らの研究では、Federated Learning の方が CWT よりも学習精度が優れていると報告している<sup>16)</sup>。また Balachandar ら<sup>15)</sup>は施設間の訓練データ数の偏りと各施設内でのクラス間の訓練データ数の偏りが混在する状況は想定できておらず、本研究のように施設間の訓練データ数の偏りと各施設内でのクラス間の訓練データ数の偏りが同時に存在するといった実際の状況に即した環境を考慮できていない。

## 3. 方法

本研究では既存の Federated Learning をベースに、施設間の医療データ数と疾病状態を表すクラス間のデータ数の偏りに対応するモデルを提案する。

### 3.1 Federated Learning

Federated Learning の概念は 2015 年 Konecný らによって提案された<sup>5)</sup>。Federated Learning の主なアイデアは、データ漏洩を防ぎつつ、複数の施設(あるいは、デバイスや計算ノード)に分散した訓練データセットにもとづく学習モデルを構築することである。Federated Learning は、各施設でデータの処理・学習モデルの訓練を行い、その学習モデルを集めることでより洗練された学習モデルを作成・再配布する。

図 2 に Federated Learning の構成と手順を図示する。図 2 の上部にあるのが全体の学習モデルを更新するサーバであり、クラウドサーバと呼ばれる。学習は図 2 の①から⑤に沿って行われる。

- ①クラウドサーバで学習モデルを作成し、各施設に配布する。
- ②各施設は配布された学習モデルを使用し、各自のデータで学習する。

- ③各施設  $i$  は得られた学習モデル更新パラメータ ( $\Delta w_i$ ) をクラウドサーバに送る。
- ④クラウドサーバは  $\Delta w_i$  を集計し、データ量に応じた学習率で学習モデルを更新する。
- ⑤更新された学習モデルを各施設に再配布する。
- ⑥ ②～⑤の手順を終了条件に一致するまで繰り返す。

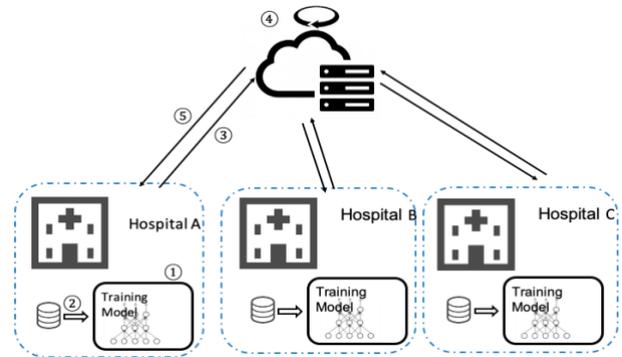


図 2 Federated Learning の構成と手順

上部にあるのがクラウドサーバと呼ばれる全体の学習モデルを更新するサーバであり、下部に各施設が存在し、訓練データは各施設から出ることはない。訓練は①から⑤の手順で行われ、②から⑤が繰り返される。

④においてクラウドサーバは、全施設から受け取った学習モデル更新パラメータ  $\Delta w_i$  を集約し、 $\Delta w_i$  に各施設のデータ量に比率する学習率を掛けて全体の学習モデルの更新に使用する。時刻  $t$  の学習モデルのパラメータを  $w_t$  とすると、時刻  $t+1$  のモデルのパラメータ  $w_{t+1}$  は以下の式により得られる。 $\eta_i$  は学習率を表す。

$$w_{t+1} = w_t - \sum_i \eta_i \Delta w_i \quad (1)$$

その後、更新された学習モデルは全ての施設と共有されるので、各施設は各自が保有している医療データを他の施設と共有せずに個別に訓練を続けることができる。

### 3.2 医療データの特徴を考慮した提案手法

本研究では、施設間のデータ数の偏りと各施設内のクラス間のデータ数の偏りが存在する環境において、学習モデルの更新式で用いる学習率を工夫することで、2つの「偏り」を同時に考慮しながら学習を行う Federated Learning の手法を提案する。具体的には、次のように新しい学習モデル更新式を提案する。パラメータ更新式(1)の学習率  $\eta_i$  を以下3つの要素で構成し動的に変更することを試みる。

$$\eta_i = \alpha_i \cdot (1 - \sigma_i) \cdot \gamma_i \quad (2)$$

$\alpha_i$  は施設間で蓄積された医療データ数の偏りを表す値であり、以下の式で求める。

$$\alpha_i = \frac{D_i}{\sum_{j=1}^N D_j} \quad (3)$$

ここで、 $N$  は学習に参加する施設数、 $D_i$  は施設  $i$  が保有するデータ数を表す。施設  $i$  のデータ量が多いほど、それに正比例し  $\alpha_i$  も大きくなる。

$\sigma_i$  は施設ごとの疾病状態を示すクラス間のデータ数の偏りを表す値であり、以下の式で求める。

$$\sigma_i = \frac{S_i}{\sum_{j=1}^N S_j} \quad (4)$$

ここで、 $S_i$  は施設  $i$  内におけるクラス間のデータ数の偏りを表しており、各クラスのデータ数の標準偏差により得られる。クラス

間の偏りが激しいほど $\sigma_i$ も大きい。

$\mu_i$ は各施設における学習の進み具合(損失の低下率)を反映しており、以下の疑似コードで1か0の値を決める。

**the Description for the Terms**

- gamma:** an array of  $\gamma_i$  in this paper.
- client\_test\_loss:** an array which includes the clients and its corresponding test loss for each client.
- index:** the serial number for the client.
- loss:** the test loss for each client.
- min\_delta:** a minimum change value that is judged as improvement for the loss. If the change in absolute value is smaller than **min\_delta**, it is considered as not improving.
- patience:** a threshold used to decide when the training will stop.
- best:** an array used to save the best loss for the study for each client.
- wait:** an array counting how much times loss is larger than the smallest one for each client.

**Algorithm**

```

Procedure get_gamma (client_test_loss, index)
1: loss = client_test_loss[ index ]
2: if (loss is not null) then
3:   gamma[ index ] = stopped_early(loss, index, 0, 32)
4: else
5:   gamma[ index ] = 0
6: if all elements in gamma equals 0 then:
7:   set all elements in gamma with 1
8: return gamma
  
```

```

Procedure stopped_early(loss, index, min_delta, patience)
1: if (loss - min_delta < best [ index ]) then
2:   best [ index ] = loss
3:   wait [ index ] = 0
4: else
5:   wait[ index ] = wait[ index ] + 1
6:   if (wait [ index ] >= patience) then
7:     return 0
8: return 1
  
```

ここで、施設ごとの学習において学習損失が全体的に減少している時、つまり、今回の学習は相対的に有効である時、パラメータが更新される仕組みとなっている。

これらの要素で構成した学習率を用いるFederated Learningを提案することで、施設間の訓練データ数の偏りや各施設内のクラス間の訓練データ数の偏りに対応することを試みる。

**4. 評価実験**

提案した Federated Learning の有効性を検証するため、Kaggleにて公開されている糖尿病眼底写真データセット17)を用いて評価実験を行った。

**4.1 実験データ**

本研究で使用した糖尿病眼底写真データセットは、糖尿病性網膜症を検出するための画像を集めたものである。これらの画像の検査によって、糖尿病に関連する眼疾患が検出され、適切な治療によって視力障害への進行が遅くなるか回避される。

データセット内の画像(図 3)は、一様でない環境において撮影されており、視覚的外観に多様性があるという特徴があ

る。一部の画像は、網膜を解剖学的に見るように表示されている(左の黄斑、右眼の右の視神経)。他にも、左右が逆になっている画像も存在する。また、焦点が合っていない、露出不足、または露出過度のアーチファクトが含まれている場合もある。

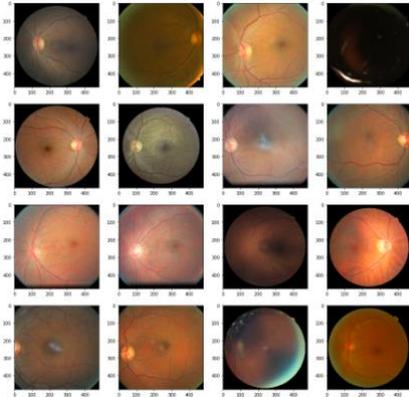


図 3 糖尿病眼底写真データの例

様々な環境で取得された糖尿病眼底写真データが含まれている。

各画像には臨床医によって糖尿病性網膜症の重症度を表すラベルが付与されている。データセットを作成した臨床医は、表 1 の定義に従い、各画像における重症度を0~4の尺度で評価してラベルを付与している。

表 1 糖尿病眼底写真データに付与されているラベル

ラベル(重症度)	定義
0	No DR
1	Mild
2	Moderate
3	Severe
4	Proliferative DR

本評価実験ではラベル 0 (No DR)を負例、ラベル 3 (Severe)を正例とし、2 値ラベル(0, 1)に変換し、全 1000 枚の画像を使用した。元のラベルの 0, 3 の例を図 4 に示す。

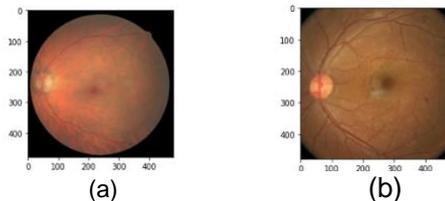


図 4 ラベル別の糖尿病眼底写真の例

(a) 元のラベル 0 (No DR)、(b) 元のラベル 3 (Severe)。

また、元のラベルと新しいラベルの対応とそれぞれのデータ数を表 2 に示す。

表 2 使用するデータ

ラベル(元)	ラベル(新)	データ数
0	0	500
3	1	500

さらに、表 3 に示すように全データを教師データとテストデータに分割する。

表 3 教師データとテストデータへの分割

	ラベル 0	ラベル 1
教師データ数	400	400
テストデータ数	100	100

## 4.2 想定環境

本研究では 2 つの施設を想定し、保持しているデータ数と疾病状態を表すクラス間のデータ数の偏りが施設間で異なる環境を設定した。また、比較例として、保持しているデータ数とクラス間のデータ数の偏りが両施設ともバランス良く保たれている環境も設定した。表 4, 5 それぞれに設定した環境における各施設の教師データ数を示す。

表 4 両施設の訓練データ数がバランスよく保たれている環境における訓練データ数

施設 ID	正例数	負例数
0	200	200
1	200	200

表 5 施設間で保持されているデータ数と疾病状態を表すクラス間のデータ数が偏っている環境における訓練データ数

施設 ID	正例数	負例数
0	350	250
1	50	150

なお、それぞれの環境における合計の訓練データ数は同じ数になるように設定した。

## 4.3 Federated Learning による学習

本実験での各施設の学習では MobileNetV2<sup>18)</sup>という高性能かつ軽量の畳み込みニューラルネットワークを学習モデルとして使用した。データを 2 クラスに変更したため、最終層のユニット数は 2 とし、softmax 関数を適用した。誤差関数は交差エントロピー、最適化手法は Adam、ミニバッチ分割数は 64、学習エポック数は 50 とした。また、学習エポックごとに Federated Learning によるパラメータの更新を行った。実装は python3 系で行い、機械学習のライブラリは scikit-learn、ディープラーニングのライブラリは tensorflow をバックエンドとした keras を用いた。

表 4 の環境において、従来手法と提案手法で学習率が変わらないため、上記学習モデルを用いて Federated Learning を 1 度行った。表 5 の環境においては、従来手法と提案手法で上記学習モデルを用いた Federated Learning をそれぞれ 1 度ずつ行った。そして、それぞれの Federated Learning を実

施している学習エポックごとにテストデータを用いて正解率を算出し、最も良い正解率を選出した。

## 4.4 結果

実験を行い、それぞれの想定環境の各学習で得られた正解率を表 6 に示す。

想定環境・提案手法による学習率の利用		正解率
訓練データ数がバランスよく保たれている環境		0.87
訓練データ数に偏りがある環境	従来手法	0.79
	提案手法	0.82

表 6 各学習における正解率

本実験において、最も正解率が高くなったのは訓練データ数がバランスよく保たれている環境で学習した場合であり、訓練データ数に偏りがある環境においては、提案手法の正解率が従来手法の正解率を上回った。

## 5. 考察

医療データの学習のために Federated Learning を用いる際に課題となる訓練データの偏りに対する提案手法の有効性について検証する。

まず、本実験において、医療データの特徴を想定しない環境に対して、想定する環境では、訓練データ数の合計が同数であるにもかかわらず、従来手法の正解率は低くなった。つまり、Federated Learning において、訓練データの偏りが正解率に負の影響を与えたと考えられる。なお、Balachandar らの研究においても同様の結果が得られており<sup>15)</sup>、従来手法では医療データが持つ課題を解決することが難しいということが示唆されている。

そして、訓練データの偏りがある環境において、従来手法よりも提案手法の正解率が良くなっており、訓練データの偏りに応じて学習率を変化させる提案手法の有効性が示唆された。

ただし、今回の実験では、2 つの施設しか想定できておらず、十分な検証が行えていないため、将来的に施設数を増やし、偏りのバリエーションも増やして検証することが必要であると考えている。

また、Federated Learning におけるプライバシー保護に関し、Federated Learning を含む分散学習手法に対して、訓練データを保持していない攻撃者が、Briland らの作成した Generative Adversarial Networks と呼ばれる攻撃<sup>19)</sup>を用いて、各施設が保持する画像データを再構築することができる可能性が指摘されている。再構築される画像データは漠然とした画像のみではあるが、患者のプライバシーが含まれている可能性もあるため、さらに秘匿性の高い手法を提案することも重要であると考えられる。

## 6. 結論

本研究では、医療施設間のデータ数に偏りがあり、かつ、クラス間のデータ数に偏りがある状況においてもロバストな分散学習を行うことを目的として、Federated Learning にもとづき各医療施設ごとに学習率を変化させる手法を提案した。

そして、公開されている糖尿病眼底写真のデータセットを用いて提案手法を検証した。糖尿病眼底写真のデータセットを施設ごとに分割し、施設間のデータ数、および、施設内でのクラス間のデータ数に偏りを持たせることで、本研究が扱う

課題を再現した想定環境を作成し、提案手法によって正解率がどのように変化するかを調べた。得られた結果から提案手法の有効性が示唆された。

ただし、本研究で行った検証は非常に限られたものであるため、今後はより多くの施設を想定する場合や他の医療データによる実験を行うことで、提案手法の有効性について検証を進めることが重要であると考えている。

## 参考文献

- 1) A Krizhevsky, I. Sutskever, G.E. Hinton. Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*: 2012; 1097-1105.
- 2) Yang Q, Liu Y, Chen T, Tong, Y. Federated Machine Learning: Concept and Applications. *ACM Transactions on Intelligent Systems and Technology (TIST)* 2019; 10.2: 1-19.
- 3) Dluhoš P, et al. Multi-center machine learning in imaging psychiatry: A meta-model approach. *NeuroImage*, 2017; 155:10-24.
- 4) 厚生労働省:医療・介護関係事業者における個人情報の適切な取扱いのためのガイドライン.2004年12月24日(2010年9月17日最終改正).  
[<http://www.mhlw.go.jp/topics/bukyoku/seisaku/kojin/dl/170805-11a.pdf> (cited 2020-Aug-25)]
- 5) Konečný J, McMahan H B, Ramage D, Richtárik P. Federated optimization: Distributed machine learning for on-device intelligence. *CoRR abs/1610.02527* 2016; arxiv:1610.02527.
- 6) Abadi M, Chu A, Goodfellow I, et al. Deep learning with differential privacy. *Proceedings of the 2016 ACM SIGSAC Conference on Computer and Communications Security* 2016; 308-318.
- 7) Gentry C, Boneh D. A fully homomorphic encryption scheme. 2009; 20.9: 1-209.
- 8) Poirot MG, Vepakomma P, Chang K, Kalpathy-Cramer J, Gupta R, Raskar R. Split Learning for collaborative deep learning in healthcare. *arXiv preprint* 2019; arXiv:1912.12115.
- 9) Chang, Ken, et al. Distributed deep learning networks among institutions for medical imaging. *Journal of the American Medical Informatics Association* 2018; 25.8: 945-954.
- 10) Wang X, Han Y, Wang C, Zhao Q, Chen X, Chen M. In-edge ai: Intelligentizing mobile edge computing, caching and communication by federated learning. *IEEE Network* 2019; 33.5: 156-165.
- 11) TAO Z, LI Q. esgd: Communication efficient distributed deep learning on the edge. *Workshop on Hot Topics in Edge Computing (HotEdge 18)* 2018.
- 12) Konečný J, McMahan H B, Yu F X, Richtárik P, Suresh A T, Bacon D. Federated learning: Strategies for improving communication efficiency. *arXiv preprint* 2016; arXiv:1610.05492.
- 13) Bhagoji A N, Chakraborty S, Mittal P, Calo S. Analyzing federated learning through an adversarial lens. *PMLR* 2019; 634-643.
- 14) Guha Roy A, Siddiqui S, Pölsterl S, Navab N, Wachinger C. Braintorrent: A peer-to-peer environment for decentralized federated learning. *arXiv preprint* 2019; arXiv:1905.06731.
- 15) Balachandar N, Chang K, Kalpathy-Cramer J, Rubin D L. Accounting for data variability in multi-institutional distributed deep learning for medical imaging. *Journal of the American Medical Informatics Association* 2020; 27.5: 700-708.
- 16) Sheller Micah J, et al. Federated learning in medicine: facilitating multi-institutional collaborations without sharing patient data. *Scientific Reports* 2020; 10.1: 1-12.
- 17) Kaggle: Diabetic Retinopathy Detection, Identify signs of diabetic retinopathy in eye images.2015  
[<https://www.kaggle.com/c/diabetic-retinopathy-detection/overview>(cited 2020-Aug-25)]
- 18) Sandler M., Howard A., Zhu M., Zhmoginov A., Chen L. C. Mobilenetv2: Inverted residuals and linear bottlenecks. In: *Proceedings of the IEEE conference on computer vision and pattern recognition* 2018; 4510-4520.
- 19) Hitaj B, Ateniese G, Perez-Cruz F. Deep models under the GAN: information leakage from collaborative deep learning. In: *Proceedings of the 2017 ACM SIGSAC Conference on Computer and Communications Security*. 603-618.