

医療診断を想定した連合学習のためのアンサンブル学習モデルの提案

1X20C084-0 博田悠斗

指導教員 後藤正幸

1. 研究背景・目的

近年、医療の領域において、診断における精度向上や効率化を図るために機械学習が活用されている。性能の高い診断システムの構築を可能にするためには、病院の垣根を越えた大量の患者データを元に診断モデルの学習を行う必要がある。しかし、実際に異なる病院間で患者データを共有することは個人情報保護の観点で適切ではないことから、それらの患者データをまとめてモデルの構築を行うことは現実的ではない。そのため、患者の個人情報保護と精度の高い診断モデルの構築を両立させることが重要な課題である。

病院間で患者のデータや属性結果を共有せずに診断モデルを開発する技術として連合学習という枠組みが知られており、現在ではその具体的な手法として Model Contrastive Federated Learning[1](以下 MOON) や Federated Ensemble Learning[2](以下 FedEL) などの手法が提案されている。しかし、パラメータ数が多い画像分類モデルを用いて、医療画像、診断 AI を開発するようなタスクにおいて、これらの手法やその単純な組み合わせでは、病院間でデータ数に偏りがある場合には十分な効果が発揮されず、精度の高い診断モデルを得ることが難しい。そこで本研究では、病院間で保有するデータに偏りがあっても両手法の効果を保持しつつ連合学習の有効性を高めることが可能となる手法を提案する。具体的には、複数の学習層から成るモデルから得られる最終出力の類似度を考慮して各病院から得られるモデルの一部に再学習を行う機構を導入する。提案手法により各病院のモデル間の乖離が最小限に抑えられ、連合学習の汎化能力を高めることが可能となる。本研究では自然画像のデータセットを用いた実験を行い、提案手法の有効性を示す。

2. 従来手法

2.1 連合学習




図 1: 水平型連合学習の概略

連合学習は、各病院で自身の所持する患者データを元にモデルの学習を行い、それらの統合を行う手法である。本研究では、図 1 に示す水平型連合学習を対象とする。 w_i^t を病院 i で t サイクル目の学習後に得られるグローバルモデルの各結合重みを保存した行列、 w^t を t サイクル目のグローバルモデルの各結合重みを保存した行列、 N を病院の数、 D_i を病院 i のデータ、 $|D_i|$ をそのサイズ、 $|D|$ を全病院のデータの

総数としたうえで、以下のようなアルゴリズムが基本となる。

STEP1) モデルの初期設定

パラメータがランダムな値に設定された w^0 をグローバルモデルの初期値に設定し、各病院にモデルの配布を行う。

STEP2) 各病院における学習の実行

各病院は、配布されたグローバルモデルをローカルモデルとして学習を行い、 w_i^t を更新する。

STEP3) 各病院の学習によって得られたモデルの統合

式 (1) のように w^t の更新を行う。

$$w^t = \sum_{i=1}^N \frac{|D_i|}{|D|} w_i^t \quad (1)$$

STEP4) グローバルモデルの各病院への配布

中央サーバーは、STEP3) で得られるグローバルモデルを各クライアントに配布し、ローカルモデルを更新する。

STEP2) から STEP4) の過程を一回の学習サイクルと定義し、指定された学習サイクル数に到達するまでこれらの過程を繰り返し実行する。

2.2 Model Contrastive Federated Learning

MOON[1] は、損失関数を患者データをローカルモデルに入力した際に得られる特徴量の集合 (以下、中間表現) とグローバルモデルに入力した際に得られる中間表現の類似度を高めるように学習を行う水平型連合学習の手法である。これにより、ローカルモデルはグローバルモデルに近づくように学習が行われるため、各病院のモデルが乖離することを防止しつつ学習を行うことができる。ここで、 τ を学習における温度パラメータ、 $\text{sim}(\cdot)$ をコサイン類似度を導出する関数、 rep を中間表現、 x を患者のデータ、 y を診断結果、 μ を二つの損失関数の比、 $R(\cdot)$ を中間表現を得るモデルの関数、 $F(\cdot)$ を最終出力を得るモデルの関数とする。

$$\ell := \ell_{\text{sup}}(w_i^t; (x, y)) + \mu \ell_{\text{con}}(w_i^{t-1}; w_i^t; w_i^t; x) \quad (2)$$

$$\ell_{\text{sup}} := \text{CrossEntropy}(F_{w_i^t}(x), y) \quad (3)$$

$$\ell_{\text{con}} := -\log \left(\frac{\exp(\text{sim}_a)}{\exp(\text{sim}_a) + \exp(\text{sim}_b)} \right) \quad (4)$$

$$\text{sim}_a := \frac{\text{sim}(R_{w_i^t}(x), R_{w_i^t}(x))}{\tau} \quad (5)$$

$$\text{sim}_b := \frac{\text{sim}(R_{w_i^t}(x), R_{w_i^{t-1}}(x))}{\tau} \quad (6)$$

2.3 Federated Ensemble Learning

FedEL[2] とは、2.1 節で述べたアルゴリズムに対し、STEP5) を学習に導入し、STEP2) \Rightarrow STEP3) \Rightarrow STEP4) \Rightarrow STEP5) \Rightarrow STEP3) \Rightarrow STEP4) の過程を一回の学習サイクルと定義し直した手法である。

STEP5) 各病院における再学習の実行

各病院は、STEP4) で配布されたグローバルモデルをローカルモデルとして、最終分類に関連するモデルの層のみを各モデルの最終出力に直接関連する重み以外のパラメータを固定した状態で連合学習を再度行う。再学習の時には学習に用いるパラメータの数が減るため、各病院のモデルの過学習が防止され、データが不均衡な場合でも十分な精度が保たれる。

3. 提案手法

3.1 提案手法への発想

MOON は、中間表現の類似度を基に学習を行うため、モデルの最終層の不均衡性を是正することができない。また、FedEL は、最終的な分類に直結する層以外のモデルのパラメータを固定するため、モデルの配布を行った時点でローカルモデルとグローバルモデルが同一になる。このことから、MOON と FedEL の手法を単純に組み合わせると、再学習時にはグローバルモデルから得られる中間表現とローカルモデルから得られる中間表現が一致してしまい、それらの類似度を基に学習を行う MOON の学習の効果が十分に得られなくなってしまう。そこで本研究では、MOON と FedEL の手法を組み合わせることで、通常の学習時は中間表現の類似度を大きく、再学習時は最終出力の類似度を大きくするように学習を行う損失関数を導入した手法 (OVERTHEMOON) を提案する。この手法により、両手法の効果を保持しながら統合でき、精度のさらなる向上が期待される。

3.2 提案手法の概要

再学習では、MOON が二種類の損失関数を用いていることを援用し、STEP2) の損失関数を MOON、STEP5) の損失関数をクロスエントロピーに変更した上で、STEP6) を以下のように導入する。また、STEP2) ⇒ STEP3) ⇒ STEP4) ⇒ STEP5) ⇒ STEP3) ⇒ STEP4) ⇒ STEP6) の過程を一回の学習サイクルと定義し直す。

STEP6) 最終出力の類似度を考慮した各病院の再学習の実行

式 (7)~(9) で定義される損失関数 ℓ_{metacon} を用いて学習を行う。 $Q(\cdot)$ をモデルの最終出力に関連する層とする。

$$\ell_{\text{metacon}} := -\log \left(\frac{\exp(\text{sim}a')}{\exp(\text{sim}a') + \exp(\text{sim}b')} \right) \quad (7)$$

$$\text{sim}a' := \frac{\text{sim}(Q_{w_i^t}(\text{rep}), Q_{w^t}(\text{rep}))}{\tau} \quad (8)$$

$$\text{sim}b' := \frac{\text{sim}(Q_{w_i^t}(\text{rep}), Q_{w_i^{t-1}}(\text{rep}))}{\tau} \quad (9)$$

4. 実験

4.1 実験条件

提案手法の有効性を確認するため、物体のカラー写真のデータセットである CIFAR-10 を医療画像と見立てて、診断のシングルラベル分類に対する提案手法の有効性を確認する。病院の数を 10、学習サイクル数を 20 として、精度を評価指標とする画像分類の実験を行う。各病院は診断結果の確率分布が不均衡になるよう、濃度ハイパーパラメータを 0.5 と

するディレクレ分布を用いてデータの分割を行い、各病院はミニバッチ勾配効果法を用いて学習を行った。学習時のハイパーパラメータは μ を 5、 τ を 1 と設定し、モデルは 7 層の CNN を使用した。比較手法として、MOON、および MOON に FedEL を導入した手法と比較して実験を行う。

4.2 実験結果

従来手法と OVERTHEMOON の精度の推移を図 2 に示す。また、最終的に得られるモデルの精度、および MOON の精度に到達するまでに必要な計算スピードの比較を行った結果を表 1 に示す。本実験より、OVERTHEMOON は従来手法より高い精度を示し、かつ計算コストの削減を実現していることがわかる。

表 1: 精度と計算コストの比較

項目	MOON	MOON+FedEL	OVERTHEMOON
画像分類の精度	65.60 (± 0.04)	64.18 (± 0.04)	68.51 (± 0.02)
計算スピード	$\times 1.0$	-	$\times 2.5$

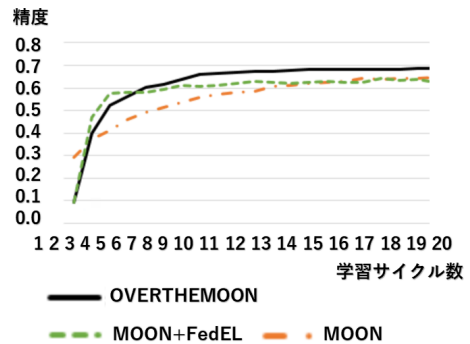


図 2: 各モデルの精度の推移

5. 考察

提案手法は病院間のデータに不均衡性を有する画像分類実験において、従来手法より各病院への過適合を防ぎつつ連合学習を行うことが可能であることが示された。社会保険制度の改定に伴い、一般的な病院と専門病院の役割分担が推進されつつある現状の医療システムにおいて、本研究で示した方法によりプライバシーを保護しつつより効果的に機械学習の導入が可能になると考えられる。

6. まとめと今後の課題

本研究では、各病院のモデルの不均衡性を是正しつつ、再学習時の効果が十分に表れる連合学習の手法を提案した。さらに、自然画像を用いた分類の実験を行うことで提案手法の有効性を示した。今後の課題として、実際の医療診断データへの適用、モデルの解釈性向上とプライバシー保護の両立などが挙げられる。

参考文献

- [1] Qinbin Li, Bingsheng He, Dawn Song “Model Contrastive Federated Learning”, the National Research Foundation, 2021.
- [2] Xing Wu, Jie Pei, Xian-Hua Han, Yen-Wei Chen, Junfeng Yao, Yang Liu, Quan Qian, Yike Guo “FedEL: Federated ensemble learning for non-iid data”, the National Natural Science Foundation of China, 2023.