



Title	6Gを見据えた大規模多層センサネットワークにおける多モーダル時空間データの解析
Author(s)	原, 惇也
Citation	サイバーメディアHPCジャーナル. 2026, 16, p. 48-51
Version Type	VoR
URL	https://doi.org/10.18910/106233
rights	
Note	

The University of Osaka Institutional Knowledge Archive : OUKA

<https://ir.library.osaka-u.ac.jp/>

The University of Osaka

6G を見据えた大規模多層センサネットワークにおける 多モーダル時空間データの解析

原 惇也

大阪大学 大学院工学研究科

1. はじめに

第6世代移動通信システム(6G)では、多数の低消費電力センサが多層的に配置された大規模ネットワークを通じて、画像、音響、振動、環境計測などの多モーダルな時空間データが広域かつ常時収集されると見込まれている。このような大規模ネットワークでは、収集されるデータが端末ごとに異なる分布を持ち、しかも総量が膨大になるため、データを1か所に集約して解析する従来の枠組みは、通信負荷とプライバシーの両面で限界に直面する。

こうしたデータを各端末に分散したまま解析する基盤として、連合学習(federated learning、以下FL)が有力である。FLは、生データを中央サーバに集約せず、各クライアントが手元のデータで局所モデルを学習し、サーバがそのモデルパラメータのみを集約して全体モデルを構築する分散学習の枠組みである。各クライアントは生データを共有せずにモデルパラメータだけを送信するため、通信量の削減とプライバシー保護を両立でき、医療、金融、IoTなど幅広い応用が期待されている[1], [2]。

一方、大規模センサネットワークでは、低消費電力かつ狭帯域の無線通信を介してパラメータが伝送されるため、フェージングやパケット損失などにより、伝送の過程で雑音や欠損が混入しやすい。劣化したパラメータをそのまま集約すると、全体モデルの精度が低下しうる。クライアント間の関係を反映せずに単純平均をとる集約は、データ分布の偏りを無視するため過平滑を招き、特に分布が偏在する状況では精度の劣化が顕著になる。

本報告では、多モーダル時空間データの解析を担う連合学習において、低電力センサ通信に伴う

雑音と欠損への頑健性を高める手法を提案する。提案手法は、クライアント間の関係を表すグラフの推定と、モデルパラメータの復元とを、単一の最適化問題として同時に解く。グラフと信号を交互ではなく同時に最適化することで、雑音を含む観測からでも両者が互いを補正し合う点に特徴がある。本問題は非凸であるが、これを凸関数の差(difference-of-convex、以下DC)計画問題に再構成し、近接DCアルゴリズム(proximal DC algorithm、以下PDCA)により局所最適解への収束を保証して解く。MNISTおよびCIFAR-10を用いた数値実験により、雑音および欠損の下で既存手法を上回る精度が得られることを示す。

2. グラフに基づく連合学習と課題

FLにおける集約とは、各クライアントの局所パラメータをサーバで束ねて全体モデルを得る処理である。代表的なFLでは、初期化、局所モデル更新、大域モデル更新の3段階を、通信ラウンドごとに繰り返す。最も単純な大域モデル更新は局所パラメータの平均であるが、クライアントごとにデータ分布が偏ると、平均は各クライアントの違いを無視するため過平滑となり、精度が落ちうる。そこで、クライアント間の関係を反映した重み付き集約が求められる。

クライアント間の関係はグラフで表現できる。各クライアントを1つの頂点に対応させ、頂点の集合と辺の集合からなるグラフを考える。グラフの各頂点上で定義されるベクトルをグラフ信号 $\mathbf{x}$ とよぶ。グラフに基づく連合学習(graph-based FL、以下GFL)は、受信したパラメータの類似度からクライアント間グラフを構成し、各クライアントの局所パラメータをグラフ信号とみなして、グラフ上で滑らかになるように集約を行う。ここ

で平滑性は、隣接行列を $\mathbf{W}$ 、グラフラプラシアンを $\mathbf{L}$ とするとき、ラプラシアン二次形式 $\mathbf{x}^\top \mathbf{L} \mathbf{x} = \sum_{(m,n) \in \mathcal{E}} [\mathbf{W}]_{mn} ([\mathbf{x}]_m - [\mathbf{x}]_n)^2$ で測られ、この値が小さいほどグラフ信号が隣接するクライアント間で滑らかに変化することを表す[3]。クラスタごとに平均をとる集約や、各クライアントの一次近傍で平均をとる集約は、いずれもこの枠組みの特殊な場合である[7], [8], [9]。

グラフが未知の場合には、滑らかなグラフ信号からグラフ自体を推定する手法を用いる[4]。これは、ラプラシアン二次形式に加えて、頂点の孤立を防ぐ項と辺の疎性を促す項を最小化する凸問題として定式化される。しかし、グラフはパラメータ間の類似度から構成されるため、パラメータが雑音や欠損を含むとグラフ自体が不正確になり、集約の品質が連鎖的に劣化する。グラフ推定とその後の集約を逐次に行う素朴な方法は、この劣化のために準最適な解に陥る。

3. グラフ推定と信号復元の同時最適化

提案手法は、クライアント間グラフの推定とパラメータの復元とを同時に行う。全体像を図1に示す。まず、伝送による劣化をモデル化する。第 k クライアントのパラメータ $\mathbf{x}_k$ は、欠損を表すマスク $\mathbf{m}_k$ と加法性白色ガウス雑音を受けて劣化し、観測モデルは次式で与えられる。

$$\tilde{\mathbf{x}}_k = \mathbf{m}_k \odot \mathbf{x}_k + \mathbf{n}_k, \quad \mathbf{n}_k \sim \mathcal{N}(\mathbf{0}, \sigma_k^2 \mathbf{I})$$

ここで $\odot$ は要素積、 $\mathbf{m}_k$ は欠損したパラメータを零とするマスクベクトル、 σ_k は雑音の標準偏差である。サーバは、各クライアントから劣化し

た観測のみを受け取り、それらを並べた行列を $\tilde{\mathbf{X}}$ と表す。

提案手法は、集約後のパラメータ Ψ とクライアント間グラフの隣接行列 $\mathbf{W}$ とを、次の最適化問題を解いて同時に推定する。

$$\min_{\Psi, \mathbf{W} \in \mathcal{W}} \frac{\mu}{2} \|\mathbf{M} \odot \Psi - \tilde{\mathbf{X}}\|_F^2 + \alpha \text{tr}(\mathbf{W} \mathcal{D}(\Psi)) - \beta \mathbf{1}^\top \log(\mathbf{W} \mathbf{1}) + \gamma \|\mathbf{W}\|_1$$

ここで $\mathbf{M}$ はマスクを並べた行列、 $\mathbf{Z} = \text{diag}(\zeta_k)$ はデータ量に応じた重み ($\|\mathbf{A}\|_F^2 = \text{tr}(\mathbf{A}^\top \mathbf{Z} \mathbf{A})$)、 $[\mathcal{D}(\Psi)]_{mn} = \|\psi_m - \psi_n\|^2$ は行間のユークリッド距離行列、 $\mathcal{W}$ は対称かつ非負で対角が零の隣接行列の集合、 $\alpha, \beta, \gamma, \mu$ は正則化パラメータである。第1項は劣化した観測への忠実性を、第2項 $\text{tr}(\mathbf{W} \mathcal{D}(\Psi))$ はラプラシアン二次形式に等しくグラフ上での平滑性を、第3項の対数障壁は各頂点が孤立しないための連結性を、第4項の ℓ_1 ノルムは辺の疎性を、それぞれ促す。マスク $\mathbf{M}$ を含む第1項により、欠損した成分はグラフ上の平滑性を通じて周囲のクライアントから補完される。

第2項は $\mathbf{W}$ と Ψ について双凸であり、問題全体は非凸であるため、有限回での収束保証を得ることは難しい。提案手法では、この双凸項を2つの凸関数の差として書き直すことで全体をDC計画問題に再構成し、PDCAによって解く。PDCAは、凹部分の勾配を用いた線形化と近接写像とを交互に適用する反復法であり、少なくとも局所最適解への収束を保証する。初期グラフは受信パラメータ間のコサイン類似度から構成し、各通信ラ




図1：提案する連合学習の全体像

ウンドの大域モデル更新の内部でこの最適化を実行する。式変形とアルゴリズムの詳細は文献[5]に譲る。

4. 数値実験

画像分類によって提案手法を評価する。MNIST および CIFAR-10 の訓練データを、偏りを制御するディリクレ分布 $\text{Dir}_K(\kappa)$ で $\kappa = 0.05$ として各クライアントに分割し、偏在した分布を模擬する。クライアント数 $K = 20$ 、通信ラウンド数 $R = 30$ とし、各クライアントは、 3×3 の畳み込み層 2 層 (ReLU 活性化と 2×2 最大プーリングを伴う) と全結合層 2 層からなる畳み込みニューラルネットワークを、学習率 $\eta = 0.01$ 、局所エポック数 $E = 5$ の確率的勾配降下法で学習する。比較手法は、標準的な FL である FedAvg[1]と FedProx[6]、グラフに基づく FL である CFL[7]、FedAMP[8]、pFedGraph[9]の 5 手法、ならびにグラフ推定と信号復元を逐次に解く 2 段階法である。伝送雑音の標準偏差は初期パラメータの平均絶対値に比例させ、比例係数 $s \in \{0.1, 0.2\}$ の 2 水準とする。提案手法の正則化パラメータは $\alpha = 0.05$ 、 $\mu = \beta = \gamma = 1$ とし、各条件について 10 試行の平均精度で評価する。

表 1 に各手法の平均精度を示す。提案手法 (PDCA) は、すべての雑音水準とデータセットで最も高い精度を達成し、逐次に解く 2 段階法を大きく上回る。これは、グラフ推定と信号復元を同時に解くことの効果を示している。図 2 は CIFAR-10、雑音水準 $s = 0.2$ におけるラウンド毎の平均精度であり、提案手法が全ラウンドを通じて一貫して既存手法を上回ることを示す。

次に、パラメータの一部をランダムに欠損させ、欠損率に対するロバスト性を評価する。図 3 に、欠損率を 0 から 0.1 まで変化させたときの平均精度を示す。提案手法は、欠損率が 10% 以下であれば精度低下を 10% 未満に抑えており、平滑性の仮定に基づいて欠損した成分を周囲のクライアントから補完できることを確認した。

表 1 : 2 つのデータセットと雑音水準 s における平均精度 (%) の比較。

手法	MNIST		CIFAR-10	
	$s=0.1$	$s=0.2$	$s=0.1$	$s=0.2$
提案 (PDCA)	95.17	92.68	83.86	78.04
提案 (2 段階法)	88.99	83.77	72.30	69.90
FedAvg [1]	90.48	89.96	77.31	74.80
FedProx [6]	90.38	90.19	76.69	74.10
CFL [7]	92.96	91.21	78.35	75.70
FedAMP [8]	93.12	92.40	78.70	75.12
pFedGraph [9]	92.76	92.01	78.19	75.24




図 2 : CIFAR-10、雑音水準 $s=0.2$ におけるラウンド毎の平均精度。





図 3 : 欠損率に対する平均精度 (上 : MNIST、下 : CIFAR-10、 $s=0.1$)。

5. おわりに

本報告では、雑音を伴う通信下での連合学習に対し、クライアント間グラフの推定とパラメータの復元とを同時に解くロバストな集約手法を提案した。集約後のパラメータがクライアント間グラフ上で滑らかに変化するという仮定のもとで、グラフとパラメータの同時最適化を DC 計画問題として定式化し、PDCA により局所最適解への収束を保証して解いた。2 つのベンチマークでの画像分類実験により、雑音および欠損の下で既存手法を上回ることを確認した。本手法は、6G で想定される大規模多層センサネットワーク上の多モーダル時空間データ解析に向けた、ロバストな分散学習基盤になりうる。今後は、より大規模なクライアント数や、画像以外のモダリティを含む実データへの適用が課題である。

謝辞

本研究の一部は、大阪大学 D3 センターの大規模計算機システム SQUID を利用した。

参考文献

- (1) B. McMahan, E. Moore, D. Ramage, and B. A. y Arcas, "Federated learning of deep networks using model averaging," arXiv:1602.05629, 2016.
- (2) P. Kairouz, H. B. McMahan, B. Avent, et al., "Advances and open problems in federated learning," Found. Trends Mach. Learn., vol. 14, no. 1-2, pp. 1-210, 2021.
- (3) D. I. Shuman, S. K. Narang, P. Frossard, A. Ortega, and P. Vandergheynst, "The emerging field of signal processing on graphs," IEEE Signal Process. Mag., vol. 30, no. 3, pp. 83-98, 2013.
- (4) V. Kalofolias, "How to learn a graph from smooth signals," in Proc. AISTATS, pp. 920-929, 2016.
- (5) J.-y. Gotoh, A. Takeda, and K. Tono, "DC formulations and algorithms for sparse optimization problems," Math. Program., vol. 169, pp. 141-176, 2018.

- (6) T. Li, A. K. Sahu, M. Zaheer, M. Sanjabi, A. Talwalkar, and V. Smith, "Federated optimization in heterogeneous networks," in Proc. Mach. Learn. Syst., vol. 2, pp. 429-450, 2020.
- (7) F. Sattler, K.-R. Müller, and W. Samek, "Clustered federated learning," IEEE Trans. Neural Netw. Learn. Syst., vol. 32, no. 8, pp. 3710-3722, 2020.
- (8) Y. Huang, L. Chu, Z. Zhou, L. Wang, J. Liu, J. Pei, and Y. Zhang, "Personalized cross-silo federated learning on non-iid data," in Proc. AAAI Conf. Artif. Intell., vol. 35, no. 9, pp. 7865-7873, 2021.
- (9) R. Ye, Z. Ni, F. Wu, S. Chen, and Y. Wang, "Personalized federated learning with inferred collaboration graphs," in Proc. ICML, pp. 39801-39817, 2023.