

マルチエージェントに基づく学習分析のための分散処理手法の実装と評価 Implementation and Evaluation of Distributed Processing Method for Multi-agent based Learning Analytics

横尾 晟希[†] 菅沼 拓夫[‡] 高橋 晶子[†]
Masaki Yokoo Takuo Suganuma Akiko Takahashi

1. はじめに

GIGA スクール構想により、全国の自治体で児童・生徒・学生（学生）の電子端末環境が整備され、学生のオンライン学習に関するデータ（学習データ）が大量かつ自動的に蓄積されるようになった。これに伴い、得られた学習データを分析し、教育・学習の改善につなげる学習分析（Learning Analytics: LA）が注目を集めている^[1]。国内における LA の現状は、大規模システムによる分析が主流であるが、単独の教育機関において LA を完結させるためには、収集される学習データ量や環境整備の面において多くの課題が残る^[2]。これに対し我々は、マルチエージェントに基づく動的な分散機械学習による LA 手法（Dynamic Distributed machine learning based LA: DynaDistLA）により、組織の規模に応じて動的に動作可能な LA 手法を提案している^[3]。本稿では、提案に基づくプロトタイプシステムを実装し、実験・評価を行うことで提案手法の分散処理の有効性を示す。

2. 関連研究と提案

大規模な LA は機械学習等に基づいており、学生の成績予測や退学予測などが盛んに行われている^[4]。また、これらの応用として分散処理手法が盛んに研究されている^[5]が、現状は中央集権型が主流であり、データ送受信時に膨大な通信オーバーヘッドが発生するため、環境整備が不十分な組織に適用することは困難である。従って、各種教育機関が LA を実施するためには、小規模な組織にも対応可能な技術基盤が必要である。

これに対し、各組織でローカルに作成された機械学習モデルを集約する連合学習（Federated Learning: FL）^[6]が提案されている。FL には様々なモデル集約手法があり、FedDist^[7]は組織毎に収集されるデータが異なることを考慮する。この手法は、ローカルモデルを集約して作成される全体モデルの更新時に、各ローカルモデルのノードと元の全体モデルのノード間の距離を計算し、その結果が閾値を超える場合にそのノードを新たに全体モデルへ追加する。これにより、全体モデルの汎化性能を損なうことなく、参加者毎での最適化も可能としている。

また、エージェント間の既存の 1 対 1 の自動交渉手法を拡張し、学習データ流通において多対 1 の自動交渉を行う手法がある^[8]。これは、情報提供者のエージェントと情報収集者のエージェント間での交渉に中立なエージェントが介入することで、グループにおけるデータ提供量をそろえることを可能としている。

本研究では、上述の研究をもとに、マルチエージェントに基づく機械学習の分散処理手法により、組織の規模に動

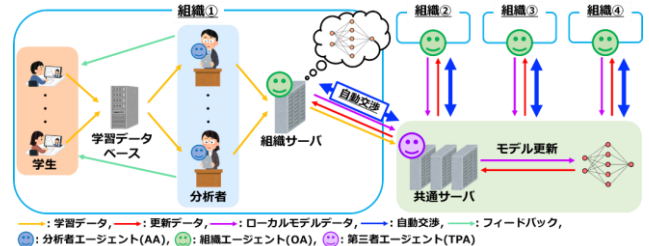


図 1 DynaDistLA の全体像

的に適応可能な DynaDistLA を提案する。

3. マルチエージェントに基づく分散処理手法の概要

本研究では、大規模な組織と協調して分析を行い、自組織のみでは得られないような分析結果を得るために FL を用いる。LA を行う際には学習データを分析しながら授業を進めていくが、このとき組織ごとに授業および機械学習モデル訓練の進行度が異なることが想定される。そこで、組織間の協調による動的な LA を実現するために、本研究では、各組織にエージェントを配置し、エージェント間の協調動作によって連携する。具体的には、FL での精度向上のために、ローカルモデルを収集するタイミングを合わせるための自動交渉を行う。

本研究で提案する DynaDistLA の概要を、図 1 に示す。分析者の代理となり、学習者から学習データを収集し、分析手法の指定などの分析者の意思を他のエージェントに共有する分析者エージェント（Analyst Agent: AA）、実際に機械学習を行いモデルの送受信や自動交渉を行う組織エージェント（Organization Agent: OA）、全体モデルの更新を行う第三者エージェント（Third Party Agent: TPA）から構成する。DynaDistLA における FL は、組織毎に収集されるデータが異なることを考慮し、モデル集約手法として 2 章で述べた FedDist^[7]を用いる。また、提案手法におけるモデル集約のタイミングについての交渉は、交渉結果がグループ内で揃えられることが望ましいため、学習データ流通における多対 1 の自動交渉手法^[8]をもとに実現する。

4. 実験と評価

4.1. プロトタイプシステムの動作確認実験

提案手法の学習データに対する動作を確認するため、DynaDistLA のプロトタイプシステムを実装し、シミュレーションによる実験を行った。

プロトタイプシステムは、FL 部分を実装し、複数の参加組織（Client）を想定して 1 台の計算機上で全ての処理を行う。本実験では、データセットとして中国語学習アプリケーションである KoToToMo Plus^[9]を利用した学生 93 名のログデータを拡張したものを用いた。このデータは、総回答時間、一日の平均学習時間などの時間系情報と、正答率

[†] 仙台高等専門学校 NIT, Sendai College

[‡] 東北大学サイバーサイエンスセンター
Cyberscience Center, Tohoku University

や全問題の完了度などの行動系情報に最終成績を加えた合計 18 種類の情報が記録されている。このデータに対し、学習モデルとして標準的な CNN モデルを使用して最終成績を予測し、成績上位者、中位者、下位者の 3 クラスに分類した。学習データは、各組織でデータが重複しないように組織毎にクラスの割合が異なるように 6 組織に分割した。モデル集約回数である通信ラウンド (Communication Round) は 50 回、100 回とした。評価指標として精度 (accuracy)、F1score を使用し、以下に示す 3 つの観点から評価した。

全体精度 (Server Train/Test) : FL で作成された全体モデルがどの程度汎化性能を持っているかを示す。全体テストデータを利用して全体モデルの精度を計算する。

ローカルモデル精度 (Client Own Train/Test) : 各組織で作成されたモデルの精度を示す。ローカルテストデータを利用してローカルモデルの精度を計算する。

汎化性能 (Client All Train/Test) : 各組織で作成されたモデルがどの程度汎化性能を持っているかを示す。全体テストデータを利用してローカルモデルの精度を計算する。

実験で得られた accuracy を図 2 に、F1Score を表 1 に示す。これらの結果から、通信ラウンドによる変化がほとんど見られないことが分かる。これは、最も良い値が算出されたベストラウンドが 50、100 付近であることから、早い段階でモデルが収束したためであると考えられる。また、各組織で作成されたローカルモデルの汎化性能と、それらを集約した全体モデルの値にほとんど差が無いことが分かる。この原因として、学習データは均質化されやすいため、組織毎のデータの差が少なく、ローカルモデルでも対応できたためだと考えられる。

4.2. 単独モデルとの比較実験

提案手法の有効性を示すため、従来の単独組織で全てのデータを処理する手法を実装し、比較した。単独モデルの実装には、4.1 の実験で用いたデータセットをクラスの偏りが無いように 5 つに分割し、1 つをテストデータ、残りの 4 つを学習用データとして用いて複数回学習・評価を行う手法である層化 k 分割交差検証を用いた。エポック数は 50 回、100 回とした。評価指標は前述のとおりである。単独モデルの結果を図 3 と表 2 に示す。この結果から、FL における各組織でローカルモデルを作成する際と同様の条件となることから、単独モデルの指標がローカルモデルの指標と類似していることが分かる。また、単独モデルと全体モデルを比較すると、全体モデルの方が僅かに低い値となっているが、同程度の結果が得られていることが分かる。よって、本提案手法は従来の単独でモデルを作成する手法と同程度の全体モデルを作成することが可能であり、有効であることを示すことができたといえる。

5. おわりに

本稿では、組織の規模によらない LA の技術基盤として、マルチエージェントに基づく機械学習の分散処理手法を提案した。これまでに、分散処理の初期実装と、学習データを用いた評価を行ってきた。今後は、自動交渉手法の実装を行っていく。

謝辞

本研究は科学研究費補助金 (22K02818) の助成を受けたものである。




図 2 (a)通信ラウンド 50 回 (b)通信ラウンド 100 回
プロトタイプシステムの accuracy

表 1 プロトタイプシステムの accuracy と F1Score

通信ラウンド	全体モデル accuracy	全体モデル F1Score	ローカルモデル F1Score	汎化性能 F1Score	サーバ ベストラウンド	クライアント ベストラウンド
50	81.50	0.8149	0.8610	0.7889	49	50
100	81.50	0.8115	0.8787	0.7872	45	96




図 3 (a)エポック 50 回 (b)エポック 100 回
単独モデルの accuracy

表 2 単独モデルの accuracy と F1Score

Epoch	accuracy	F1Score	Train ベストラウンド	Test ベストラウンド
50	85.93	0.8593	49	49
100	86.26	0.8595	98	57

参考文献

- [1] 緒方広明, “ラーニングアナリティクスの研究動向-エビデンスに基づく教育の実現に向けて-”, 情報処理学会誌, Vol.59, No.9, pp.796-799 (2018)
- [2] 田村恭久, “ラーニングアナリティクスとモデリング”, 人工知能学会誌, 第 35 卷 2 号, pp.234-240 (2020)
- [3] 横尾晟希 他, “マルチエージェントに基づく学習分析のための分散処理手法の設計”, 第 86 回全国大会講演論文集, 情報処理学会, pp.123-124 (2024)
- [4] Ifenthaler, D. and Yau, J. Y. K. “Utilising learning analytics to support study success in higher education: asystematic review”, Educational Technology Research and Development, Vol.68, pp.1961-1990 (2020)
- [5] 比戸将平, “並列分散環境における機械学習技術の最新動向”, 電子情報通信学会誌, Vol.98, No.1, pp.54-58 (2015)
- [6] McMahan, B. et al. “Communication-efficient learning of deep networks from decentralized data”, In: *Artificial Intelligence and Statistics*, PMLR, Vol.54, pp.1273-1282 (2017)
- [7] Sannara, E. K. et al. “A federated learning aggregation algorithm for pervasive computing: Evaluation and comparison”, In: 2021 IEEE International Conference on Pervasive Computing and Communications (PerCom), IEEE, pp.1-10 (2021)
- [8] 早坂喜哉 他, “マルチエージェントを用いた学習データ流通のための自動交渉手法の基本設計”, 第 85 回全国大会講演論文集, 情報処理学会, pp.71-72 (2023)
- [9] 児玉雅明 他, “ブレンド型初修外国語教育における持続的な復習活動を可能とするスマートフォン学習教材の開発と評価”, 研究報告教育学習支援情報システム (CLE), Vol.18, pp.1-8 (2019)