

## オープンソース LLM を利用した学習アドバイジングの検証 Validation of Learning Advising using an Open Source LLM

釣部 勇人<sup>†</sup> 上野 春毅<sup>‡</sup> 長谷川 理<sup>§</sup> 小松川 浩<sup>†</sup>  
Taketo Tsurube Haruki Ueno Osamu Hasegawa Hiroshi Komatsugawa

### 1. はじめに

近年の学習支援教育では、生涯学習習慣や主体的に考える力を持ち、予測困難な時代の中でどんな状況にも対応できる多様な人材の育成が求められている。こうした人材の育成には学習者が自ら学習を進め学習状況を振り返ることができる主体的かつ自律的な学習が重要となる。しかしながら、学生主体の学習に慣れていない学習者は自ら学習を進めることが難しく、主体性を身に着けることが困難である。本来、こうした学習者に対して教員が学習状況や振り返り等から学習者の状況を察し、支援することが求められるが、学生の状況を毎週確認することは難しい。

この課題に対して本研究チームでは、先行研究において ChatGPT を活用して学習者の状況に応じたアドバイジングを自動化する仕組みを提案し検証をしてきた[1]。学習者特性に合わせたアドバイスの生成が示唆された一方、効果的なアドバイスの提示に求められる教育理論の視点は、汎用目的で開発された大規模言語モデル (Large Language Models; LLM) においては十分に考慮されない可能性がある。さらに、アドバイスの個別化のためには各学習者の情報を組み込む必要があり、プライバシーやセキュリティの観点で ChatGPT を利用できない懸念がある。

近年、ChatGPT のような大規模なパラメータをもったクロード LLM の文章生成性能が注目される一方で、モデルのカスタマイズ性や機密性、透明性の観点からローカル上で動作するオープンソース LLM の開発が進められている。特にドメインへの適用においては、JMedLoRA(医療)[2]や nekomata-14b-pfn-qfin(金融)[3]といった汎用 LLM をベースにしたドメイン特化モデルが開発されている。しかしながら、教育領域への適用は他言語では実施されているものの日本語においてはほとんど行われていない。

以上を踏まえ本研究では、自動学習アドバイジングへのオープンソース LLM の活用及びオープンソース LLM の教育ドメインへの適用を目指す。具体的には、教育ドメインの中でも学習アドバイスへの関連が強い自己調整学習に関するテキストデータに基づき学習用データセットを構築し、自己調整学習ドメインの適用を目標とする。

### 2. 研究の目的

本研究では、学習アドバイジングをオープンソース LLM に置き換えた際に生成結果にどの程度の変化が見られるか検証する。また、先行研究で用いた ChatGPT 及びドメイン適用前のベースモデル、ドメイン適用後のモデルの

<sup>†</sup> 公立千歳科学技術大学 大学院理工学研究科, Graduate School of Science and Technology, Chitose Institute of Science and Technology

<sup>‡</sup> 公立千歳科学技術大学 理工学部, Faculty of Science and Technology, Chitose Institute of Science and Technology

<sup>§</sup> 武蔵野大学 データサイエンス学部, Department of Data Science, Musashino University

3 モデル間での生成結果について比較する。

### 3. 検証

本研究では、まずドメイン適用前のベースモデルを用いてアドバイスを生成し、ChatGPT(GPT-3.5 Turbo)による生成結果と比較する。次に、少量の自己調整学習テキストデータを用いてベースモデルに対してファインチューニングを行い、生成された応答を検証する。ベースモデルとして Llama3-70B-Instruct を利用した。このモデルは Meta 社が開発した約 700 億パラメータをもつ LLM であり、事前学習に加えて Instruction tuning が実施されている。本実験では、Llama-3-70B-Instruct に QLoRA を活用したファインチューニングを行うことで、自己調整学習の知識獲得を図る。

#### 3.1 オープンソース LLM によるアドバイスの評価

先行研究と同様のプロンプトを用いて学習アドバイスを行うことで各モデルの生成結果を比較した。プロンプトには学習者の情報が含まれており、LMS (Learning Management System) 上で収集された学習履歴と学習者によって記述された目標設定/振り返りで構成される。学習者の情報として用いる項目を表 1 に示す。

表 1 学習履歴及び振り返り情報の項目

	項目名
学習履歴	教科書閲覧時間
	演習取り組み回数
	ワークシート取り組み状況
	理解度テストのスコア
	グループワークへの参加
	グループワークへの貢献度
振り返り情報	1週間前に立てた今週の目標
	今週の目標の達成度
	達成度の理由

表 2 各クラスタの学習者特性

	教科書	演習	ワークシート	理解度テスト	GW参加	GW貢献度
順調型	△	△	◎	○	◎	◎
教科書やりこみ型	◎	△	○	○	○	○
演習やりこみ型	△	◎	△	◎	△	△
伸び悩み型	△/×	△/×	△/×	×	×	×

また、評価データとして A 大学の 2021 年度講義「C プログラミング」の 7 週目の授業データ(90 名)の学習履歴及び振り返り情報を用いた。先行研究において、学習者は学習者特性ごとに 4 つのクラスタに分類することができるとされる。各クラスタと学習者情報の関係を表 2 に示す。表中の記号は各項目の達成度を示しており、「◎, ○, △, ×」の順に達成度が高い。

本研究では自己調整学習ドメインにおける評価のために、学習者特性に合わせてアドバイスが行われているかを評価指標とし、各モデルのアドバイスによって言及されている項目と各クラスタの学習者特性との合致を比較する。

### 3.1.1 ベースモデルによるアドバイス生成の評価

ベースモデルである Llama3-70B-Instruct (Llama3-base と表記)と先行研究の ChatGPT によるアドバイス生成結果を比較する。各モデルの生成結果の学習履歴及び振り返りへの言及割合を表 3、それぞれのモデルの詳細な各項目への言及割合を表 4、表 5 に示す。表 4 における「不適切ではないアドバイス」は Hallucination を含まないアドバイスの割合を示す。

表 4 より、ベースモデルの学習履歴及び振り返りへの言及割合はともに ChatGPT を上回っており、どちらの学習者の情報を考慮してアドバイスが行われていることが分かる。また、不適切ではないアドバイスの割合は 97.78% と ChatGPT と同等であり、オープンソース LLM への置き換えによる精度の低下はみられない。

先行研究において、表 2 と表 4 の関係から ChatGPT によるアドバイスはクラスタの達成度が低い項目への言及割合が高く、未達成項目への改善を促す傾向にあるとされた。それに対し、Llama3-base は表 4、表 5 より達成度が△~×である項目は 70%以上であるものが多く、ChatGPT と同様に改善を促す傾向が確認された。一方で、演習やりこみ型の演習や順調型の GW 貢献度など達成度が高い項目への言及割合が高い。これらの項目では長所の維持とさらなる成長を促す傾向にあり、学習者の弱みと強みの両方面に対しバランスの取れたアドバイスが可能であると示唆される。

表 3 アドバイスの学習履歴及び振り返りへの言及割合

Model	学習履歴	振り返り	学習履歴 振り返り 混合	不適切ではない アドバイス
ChatGPT	98.89%	72.22%	71.11%	97.78%
Llama3-base	100%	81.11%	81.11%	97.78%

表 4 ChatGPT によるアドバイスの各項目への言及割合

到達段階	教科書	演習	ワーク シート	理解度 テスト	GW 参加	GW 貢献度	学習者数
順調型	78.00%	76.00%	10.00%	20.00%	22.00%	26.00%	50
教科書やりこみ型	33.33%	100.00%	0.00%	33.33%	33.33%	33.33%	3
演習やりこみ型	71.43%	0.00%	14.29%	0.00%	42.86%	28.57%	7
伸び悩み型	90.00%	80.00%	46.67%	16.67%	86.67%	13.33%	30

表 5 Llama3-base によるアドバイスの各項目への言及割合

到達段階	教科書	演習	ワーク シート	理解度 テスト	GW 参加	GW 貢献度	学習者数
順調型	84.00%	74.00%	20.00%	34.00%	2.00%	62.00%	50
教科書やりこみ型	0.00%	66.67%	66.67%	66.67%	33.33%	33.33%	3
演習やりこみ型	85.71%	85.71%	14.29%	42.86%	14.29%	71.43%	7
伸び悩み型	90.00%	66.67%	33.33%	26.67%	86.67%	20.00%	30

## 3.2 学習手法

次に、ベースモデルを自己調整学習ドメインへ適用するためにファインチューニングを行う。大量の計算資源を必要とする LLM の追加学習では、一部のパラメータのみを対象とすることで効率よくファインチューニングを行う手法がいくつか提案されている。LoRA(Low-Rank Adaptation) [4]は、効率的なファインチューニング手法の一つであり、事前学習済み LLM に対して低ランク行列を適応させることで学習時のパラメータ数を削減できる。また、LoRA に量子化を取り入れた QLoRA[5]が提案されており、計算資源の限られた環境においても大規模モデルのファインチューニングが可能となる。

そこで本研究では、QLoRA を用いたファインチューニングによってドメイン特化モデルを構築する。

## 3.3 自己調整学習ドメインの追加学習

ファインチューニングを実施するために J-STAGE(2024 年 6 月時点)に登録されている自己調整学習に関連する日本語文献 896 件(約 20M tokens)を利用し、自己調整学習データセットを構築した。このデータセットは、一つの分野に限らず、小中高等教育、スポーツ、医療等の多様な分野における自己調整学習の文献を含む。

## 4. おわりに

本研究では、学習アドバイジングをオープンソース LLM へ置き換えた際の生成結果について検証した。学習履歴及び振り返り情報への言及割合は ChatGPT と同等以上となり、学習者の情報を考慮したアドバイスの生成が確認された。また、短所の改善を促すだけでなく長所のさらなる育成を促すアドバイスが確認された。これらのことからオープンソース LLM による学習アドバイジングが十分に可能であると考えられる。また、ドメイン適用後モデルのアドバイス生成検証については口頭発表にて提示する。

### 謝辞

本研究は JSPS 科研費 JP24K03054 の助成を受けたものである。また本研究の実験は、武蔵野大学の協力を受け提供された環境下で行われたものである。

### 参考文献

- [1] Yasuomi Takano, Taketo Tsurube, Haruki Ueno and Hiroshi Komatsugawa, "A Proposal and Evaluation of Learning Advising using a Generative AI", 31th International Conference on Computers in Education Work In Progress Posters Proceedings, pp. 872-874, 2023
- [2] Issey Sueda, Masahiro Suzuki, Hiroki Sakaji and Satoshi Kodera. "JMedLoRA: Medical Domain Adaptation on Japanese Large Language Models using Instruction-tuning". arXiv e-prints, pp. arXiv-2310, 2023
- [3] Masanori Hirano, Kentaro Imajo. "Construction of Domain-specified Japanese Large Language Model for Finance through Continual Pre-training", arXiv e-prints, pp. arXiv-2404, 2024
- [4] Edward J Hu, Phillip Wallis, Zeyuan Allen-Zhu, Yuanzhi Li, Shean Wang, Lu Wang, Weizhu Chen, et al. "Lora: Low rank adaptation of large language models". In International Conference on Learning Representations, 2021.
- [5] Tim Detmers, Artidoro Pagnoni, Ari Holtzman, and Luke Zettlemoyer. "Qlora: Efficient finetuning of quantized llms". arXiv e-prints, pp. arXiv-2305, 2023.