

LoRA を用いた Fine-tuning 済み SBERT によるコース推薦

土田詩音¹ 佐々木稔¹
¹茨城大学大学院 理工学研究科

25nm754l@vc.ibaraki.ac.jp, minoru.sasaki.01@vc.ibaraki.ac.jp

概要

学習者の自由記述 (PR 文) とコース概要を意味的に対応付けるコース推薦手法を提案する. 提案手法は Sentence-BERT に Low-Rank Adaptation (LoRA) を導入し, 計算コストを抑えつつドメイン適応を行う. さらに, PR 文とコース概要という言語的特性の異なる入力を個別に捉えるため, SBERT に 2 系統の LoRA adapter を適用する Dual Adapter アーキテクチャを採用する. 企業研修コース概要データを用いた実験では, 提案法は標準 SBERT および Shared Adapter LoRA より高い適合率を示し, Full Fine-tuning に近い性能を少ない学習量で達成した.

キーワード: 科目推薦, 推薦システム, Sentence-BERT, LoRA, Parameter-Efficient Fine-Tuning

1 はじめに

学習者が自身の興味や目標に合う科目・研修を選ぶことは重要である一方, 科目名や短い説明だけでは内容の把握が難しく, ミスマッチが生じやすい. そこで本研究は, 学習者の PR 文とコース概要をテキストとして扱い, 意味的類似度に基づいて推薦する手法を提案する. SBERT により両テキストを埋め込み表現へ変換し, LoRA による効率的 Fine-tuning で企業研修ドメインへ適応させる. 特に, PR 文とコース概要の文体差を考慮し, 入力種別ごとに独立した LoRA adapter を適用する Dual Adapter を導入する.

2 関連研究

本研究は, (i) コース推薦における意味的マッチング, (ii) 複数ステークホルダーおよび制約を考慮した推薦, (iii) パラメータ効率の良いモデル適応の交点に位置付けられる.

2.1 従来手法から意味的マッチングへ

初期のコース推薦は協調フィルタリング [19] やコンテンツベース [17] が中心であったが, 教育ドメインではコールドスタート問題やデータのスパース性により性能が低下しやすい [19], [17], [16]. 近年は, シラバスや学生プロフィールなどのテキストを直接扱うため, Transformer ベースの表現学習へ移行している [8]. とりわけ SBERT [18] は文埋め込みを介して, 学習者記述とコース記述の意味的類似度を効率的に計算でき, 本研究の基盤となる [12].

2.2 マルチステークホルダーおよび制約ベースの推薦

実環境のコース選択は, 学生の嗜好だけでなく, 前提科目や学位要件などの Hard な制約により制限される [6], [7]. また MSRS は, 利害の異なる複数当事者を前提に推薦を設計する枠組みであり [1], [2], [3], 教育文脈では学生に加えて教員・大学もステークホルダーとなる [5], [11], [22]. 一方で, 教員の担当希望や学科の方針といった提供者側の動的な Soft な制約を体系的に取り込む実用的手法は十分でない. 本研究は, 提供者側選好を明示的にモデル化・統合することでこの課題に対処する.

2.3 LoRA によるパラメータ効率の良い Fine-tuning

大規模事前学習モデルをドメインデータで Fine-tuning することは有効だが [18], [20], [21], Full Fine-tuning は計算資源の負担が大きい [10], [13]. PEFT [9] の代表である LoRA [10] は, 元の重みを凍結し低ランク行列のみを学習することで, 学習量を抑えつつ性能を維持できる. LoRA は推薦分野でも主に LLM のシーケンシャル推薦で用いられているが [4], [15], [14], 本研究は SBERT による意味的マッチングを LoRA で効率的に適応し, さらに PR 文とコース記述の入力種別の差を扱うために Adapter を分離する点に新規性がある.

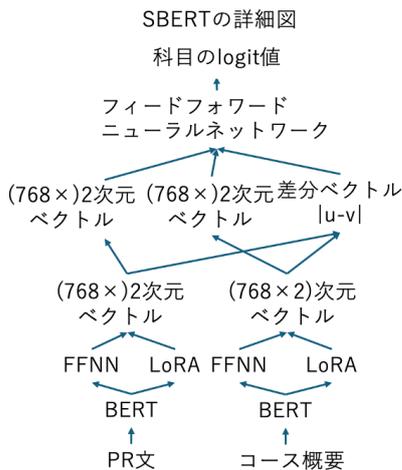


図1 モデル全体のアーキテクチャ

3 手法

本節では、学習者のPR文とコース記述を用いて、個々の学習者に最適化されたコースを推薦するモデルの構築手法を述べる。提案手法は **Sentence-BERT [18]** に基づき、Low-Rank Adaptation (LoRA) を用いた効率的な Fine-tuning を特徴とする。

提案する推薦システムの全体アーキテクチャを図1に示す。本システムは、学習者(従業員)および管理者(上司)の双方からのテキスト入力を受け付け、SBERTを用いてベクトル表現へ変換する。

具体的には、1) 学習者のプロフィール (PR文) と 2) 研修コース概要からなるテキスト対を、SBERTモデルで処理する。このモデルはDual Adapterアーキテクチャを採用し、独立なLoRA Adapterを各テキスト種別に適用することで、それぞれのドメイン固有特性を効率的に学習する。

3.1 学習者プロフィールのベクトル化

学習者の入力データであるPR文は、学習動機と興味を表す重要なテキストである。このテキストを事前学習済みSBERTモデルに入力し、PR文の語と文脈を解釈して高次元特徴を抽出する。

次に、文全体の意味を単一ベクトルへ集約するため、Pooling(本研究ではMean-pooling)を適用する。これにより、PR文は意味的特性を保持した768次元の固定長ベクトル u として表現される。この過程には、学習者の記述スタイルやニュアンスの学習に

特化したLoRA Adapterが組み込まれる。

3.2 コース記述のベクトル化

コース側データであるコース記述テキストも同様の手順でベクトル化する。コース記述は専門用語や客観的記述を多く含み、学習者プロフィールとは異なる言語的特性を有する。

そのため、コース記述テキストは、専用のSBERTモデルに入力される(学習者側モデルと重みは共有するが、独立なLoRA Adapterを持つ)。学習者プロフィールと同様に、BERTによる特徴抽出とPoolingを経て、コース記述を768次元ベクトル v へ変換する。このモデルにも、シラバス特有の文体に適應する別のLoRA Adapterを備える。

3.3 特徴ベクトルの結合

次に、学習者とコースという2つの異なるテキストソースから得られたベクトルを統合し、両者の関係を表す特徴ベクトルを作成する。具体的には、以下の3つのベクトルを結合する。

- **ベクトル u :** 学習者プロフィールから生成された768次元ベクトル。
- **ベクトル v :** コース記述から生成された768次元ベクトル。
- **差分ベクトル $|u-v|$:** u と v の要素ごとの絶対差から得られるベクトルであり、2つのテキスト間の意味的距離を明示的に与える。

これら3つのベクトルを結合することで、より情報量の多い単一の特徴ベクトルを得る。

3.4 FFNNによるモデル学習

前段で作成した結合特徴ベクトルを、最終分類器であるFeed-Forward Neural Network (FFNN)に入力する。FFNNは、PR文とコース記述の元のペアが意味的に適合(label: 1)か不適合(label: 0)かを判定するよう学習される。

学習には、専門家が適合または不適合を付与したラベル付きデータセットを用いる。この教師あり学習により、特徴ベクトルにおける適合として分類すべきパターンを学習する。

3.5 定性評価と推論

モデル学習後、推薦性能を評価する推論テストを行う。テストでは、学習に用いていないPR文と

コース記述のペアを入力し、出力スコア（0 から 1 の確率値）を評価する。

例えば、「ネットワークセキュリティ技術や、OS のセキュリティ機能、コンピュータウイルス対策について学びたい」といった PR 文を入力すると、モデルは各コースに対する適合スコアを算出する。このスコアに基づきコースを降順に並べることで、学習者の要望に合致する推薦リストを生成する。実験の結果、『IT エンジニアのためのセキュリティ基礎』がスコア 0.9997 で 1 位に推薦され、モデルが適切に機能していることが示唆された。

4 実験

4.1 目的

本実験の目的は、提案する **LoRA-SBERT (Dual Adapter)** モデルの有効性を包括的に検証することである。具体的には、以下の 2 点を明らかにする。

1. **LoRA ベースの Fine-tuning の有効性:** LoRA を用いる軽量な Fine-tuning が、全層を更新する Full Fine-tuning と同等またはそれ以上の推薦精度を達成できるかを、計算コスト削減の観点と併せて検証する。
2. **Dual Adapter アーキテクチャの優位性:** 学習者と講師（コース提供者）のテキストドメインに対して独立な Adapter (Dual Adapter) を適用することが、単一 Adapter を共有する場合に比べて精度向上へ寄与するかを調査する。

評価は、客観的な評価指標を用いて、ベースラインおよび比較モデルと提案モデルの性能を比較することで行う。

4.2 データセットの詳細

実験には、Hitachi, Ltd. Academy¹⁾が提供する企業研修プログラムのコース概要データを用いた。データセットは、学習者の PR 文とコース記述テキストのペアから構成される。

学習者 PR 文は、特定の研修カテゴリ（例：セキュリティ、ネットワーク）に関心を持つ学習者を想定し、ChatGPT を用いて実際の業務日報の文体を模倣しつつ多様な表現となるよう合成的に生成した。コース記述テキストは、上記 Web サイトから収集した実際のコース概要である。

1) <https://www.hitachi-ac.co.jp/>

各テキストペアには 2 値ラベルを付与した。具体的には、PR 文のカテゴリとコース記述のカテゴリが一致する場合を適合 (label: 1)、明らかに無関係な場合を不適合 (label: 0) とした。

4.3 実験モデル

提案手法の有効性を評価するため、以下の 4 モデルを比較した。

SBERT (Base) Fine-tuning なしで用いる事前学習済みモデル (sonoisa/sentence-bert-base-japanese-mean-tokens-v2)。本実験のベースラインである。

Full Fine-tuned SBERT Transformer ブロック内の全パラメータを含むベースモデル全体をデータセットで Fine-tuning したモデルである。理論上の性能上限を表すことが期待される一方、計算コストが高く過学習リスクもある。

LoRA-SBERT (Shared Adapter)

単一の LoRA Adapter をベースモデルへ挿入し、学習者・講師テキスト処理で重みを共有するモデルである。LoRA の基本的有効性を測定するために用いる。

LoRA-SBERT (Dual Adapter)

提案手法である。学習者ドメインおよび講師ドメインの SBERT に独立な LoRA Adapter を挿入し、それぞれがドメイン固有特性を個別に学習できるようにする。

4.4 学習設定

全ての Fine-tuning 実験で、以下のハイパーパラメータを共通に用いた。

- **Base Model:** sonoisa/sentence-bert-base-japanese-mean-tokens-v2
- **Optimizer:** AdamW
- **Learning Rate:** 2e-5
- **Batch Size:** 32
- **Epochs:** 4
- **LoRA Rank:** 8
- **LoRA Alpha:** 16

4.5 評価指標

モデルの性能は、分類タスクで一般的な以下の指標により評価した。

- **Accuracy:** 全インスタンスのうち正しく分類さ

表 1 モデルの性能比較

Model	Acc.	Prec.	Rec.	F1	Time [s]
SBERT (Base)	0.2937	0.1835	0.9248	0.3063	N/A
Full Fine-tuned	0.9669	0.8942	0.9118	0.9029	230
LoRA (Shared)	0.9537	0.8801	0.8399	0.8595	179
LoRA (Dual)	0.9603	0.9179	0.8399	0.8771	179

* LoRA (Shared): Shared Adapter

* LoRA (Dual): Dual Adapter (提案手法)

れた割合.

- **Precision:** 適合 (正例) と予測されたもののうち真に適合であった割合.
- **Recall:** 実際の適合データのうち正しく同定された割合.
- **F1-Score:** Precision と Recall の調和平均であり, 性能のバランスを評価する.

5 結果と考察

各モデルの性能を定量的評価と定性的評価の両面から述べる.

5.1 定量的評価

テストデータにおける性能を表 1 に示す.

SBERT (Base) は F1 値が低く, Recall が高い一方で Precision が低いことから, 多くを適合と予測する傾向が見られた. このため, 本タスクではドメイン固有の Fine-tuning が不可欠である. LoRA (Shared) と LoRA (Dual) は Full Fine-tuning に近い F1 値を維持しつつ学習時間を短縮した. さらに LoRA (Dual) は LoRA (Shared) より F1 値と Precision が高く, PR 文とコース記述で Adapter を分離する設計が適合予測の信頼性向上に寄与したと考えられる.

5.2 定性的評価

セキュリティ関連の PR 文に対し, SBERT (Base) は無関係なコースを上位に含む一方, Fine-tuning 済みモデルは関連コースを上位に推薦した. 特に LoRA (Dual) は前述の『IT エンジニアのためのセキュリティ基礎』のような高関連な推薦を示し, 定量的結果の Precision 向上と整合した.

5.3 考察

以上より, LoRA による SBERT の Fine-tuning は企業研修におけるコース推薦で有効であり, 性能と計算効率の両立に寄与する. また LoRA (Dual) は LoRA (Shared) を F1 値と Precision で上回り, 文体や

語彙が異なる二つのドメインに対して Adapter を分離する設計の有用性を支持する. Accuracy は Full Fine-tuning にわずかに及ばないものの, 実用上は有望なトレードオフを提供する.

6 結論と今後の課題

PR 文とコース概要の意味的対応付けに基づく推薦手法を提案し, SBERT に LoRA を導入して効率的な Fine-tuning を実現した. さらに, 入力種別ごとに独立 Adapter を適用する Dual Adapter により, Shared Adapter より高い Precision と F1 値を得た. 今後は, 真正な学習者データでの検証, 大学シラバス等への適用, および前提条件など制約を統合した実運用検証を行う.

謝辞

本研究は株式会社ラフトレイド・エンジニアリングの支援を受けたものである.

参考文献

- [1] Himan Abdollahpouri, Gediminas Adomavicius, Robin Burke, Ido Guy, Dietmar Jannach, Toshihiro Kamishima, Jan Krasnodebski, and Luiz Pizzato. Multistakeholder recommendation: Survey and research directions. *User Modeling and User-Adapted Interaction*, 30(1):127–158, March 2020.
- [2] Himan Abdollahpouri and Robin Burke. Multistakeholder recommender systems. In F. Ricci, L. Rokach, and B. Shapira, editors, *Recommender Systems Handbook*, pages 647–677. Springer, New York, NY, USA, 3rd edition, 2022.
- [3] Himan Abdollahpouri, Robin Burke, and Bamshad Mobasher. Controlling popularity bias in learning-to-rank recommendation. In *Proc. 11th ACM Conf. Recommender Systems (RecSys '17)*, pages 42–46, August 2017.
- [4] Keqin Bao, Jizhi Zhang, Yang Zhang, Wenjie Wang, Fuli Feng, and Xiangnan He. TALLRec: An effective and efficient tuning framework to align large language model with recommendation. In *Proc. 17th ACM Conf. Recommender Systems (RecSys)*, pages 1007–1014, September 2023.
- [5] Robin Burke and Himan Abdollahpouri. Educational recommendation with multiple stakeholders. In *Proc. IEEE/WIC/ACM Int. Conf. Web Intelligence Workshops (WIW)*, pages 62–63, October 2016.
- [6] Hana Bydžovská. Course enrollment recommender system. In *Proc. 9th Int. Conf. Educational Data Mining (EDM 2016)*, pages 312–317, June 2016.
- [7] Abderrahim Chanaa and Noureddine El Faddouli. Prerequisites-based course recommendation: recommending learning objects using concept prerequisites and meta-data matching. *Smart Learning Environments*, 11(6),

2024. DOI: 10.1186/s40561-024-00301-0.

- [8] Hussien A. Mohamed Hassan, Giuseppe Sansonetti, Fabio Gasparetti, Alessandro Micarelli, and Joeran Beel. BERT, ELMo, USE and InferSent sentence encoders: The panacea for research-paper recommendation? In **Proc. ACM RecSys 2019 Late-breaking Results co-located with 13th ACM Conf. Recommender Systems (RecSys 2019)**, volume 2431, pages 6–10, September 2019.
- [9] Neil Houlsby, Andrei Giurgiu, Stanislaw Jastrzebski, Bruna Morrone, Quentin De Laroussilhe, Andrea Gesmundo, Mona Attariyan, and Sylvain Gelly. Parameter-efficient transfer learning for NLP. In **Proc. 36th Int. Conf. Machine Learning (ICML)**, volume 97, pages 2790–2799, June 2019.
- [10] Edward J. Hu, Yelong Shen, Phillip Wallis, Zeyuan Allen-Zhu, Yuanzhi Li, Shean Wang, Lu Wang, and Weizhu Chen. LoRA: Low-rank adaptation of large language models. In **Proc. 10th Int. Conf. Learning Representations (ICLR)**, April 2022.
- [11] Dietmar Jannach and Gediminas Adomavicius. Recommendations with a purpose. In **Proc. 10th ACM Conf. Recommender Systems (RecSys)**, pages 7–10, September 2016.
- [12] Betren Juarto and Abba Suganda Girsang. Neural collaborative with Sentence BERT for news recommender system. **JOIV: Int. J. Informatics Visualization**, 5(4):282–287, 2021.
- [13] Josip Jukić and Jan Šnajder. Parameter-efficient language model tuning with active learning in low-resource settings. In **Proc. 2023 Conf. Empirical Methods in Natural Language Processing (EMNLP)**, pages 5061–5074, December 2023.
- [14] Xiangyang Kong, Jiancan Wu, An Zhang, Leqi Sheng, Hongyu Lin, Xiang Wang, and Xiangnan He. Customizing language models with instance-wise LoRA for sequential recommendation, 2024. <https://arxiv.org/abs/2408.10159>.
- [15] Jiayi Liao, Sihang Li, Zhen Yang, Jiancan Wu, Yancheng Yuan, Xiang Wang, and Xiangnan He. LLaRA: Large language-recommendation assistant. In **Proc. 47th Int. ACM SIGIR Conf. Research and Development in Information retrieval (SIGIR)**, pages 1785–1795, July 2024.
- [16] Aditya Parameswaran, Hector Garcia-Molina, Hyunjung Park, Neoklis Polyzotis, and Jennifer Widom. CourseRank: A system for collaboratively ranking courses. In **Proc. 2010 ACM SIGMOD Int. Conf. Management of Data**, pages 1183–1186, June 2010.
- [17] Michael J. Pazzani and Daniel Billsus. Content-Based Recommendation Systems. In **The Adaptive Web: Methods and Strategies of Web Personalization**, volume 4321 of **Lecture Notes in Computer Science**, pages 325–341. Springer, Berlin, Germany, 2007.
- [18] Nils Reimers and Iryna Gurevych. Sentence-BERT: Sentence embeddings using siamese BERT-networks. In **Proc. 2019 Conf. Empirical Methods in Natural Language Processing and 9th Int. Joint Conf. Natural Language Processing (EMNLP-IJCNLP)**, pages 3982–3992, November 2019.
- [19] Paul Resnick, Neophytos Iacovou, Mushon Suchak, Peter Bergstrom, and John Riedl. GroupLens: An open architecture for collaborative filtering of netnews. In **Proc. 1994 ACM Conf. Computer Supported Cooperative Work (CSCW '94)**, pages 175–186, October 1994.
- [20] Kexin Wang, Nils Reimers, and Iryna Gurevych. TS-DAE: Using transformer-based sequential denoising auto-encoder for unsupervised sentence embedding learning. In **Findings of the Association for Computational Linguistics: EMNLP 2021**, pages 671–688, November 2021.
- [21] Kexin Wang, Nandan Thakur, Nils Reimers, and Iryna Gurevych. GPL: Generative pseudo labeling for unsupervised domain adaptation of dense retrieval. In **Proc. 2022 Conf. North American Chapter of the Association for Computational Linguistics: Human Language Technology (NAACL)**, pages 2345–2360, July 2022.
- [22] Yong Zheng. Multi-stakeholder personalized learning with preference corrections. In **Proc. 18th IEEE Int. Conf. Advanced Learning Technologies (ICALT)**, pages 108–110, July 2018.