

疑似グラフデータ学習による LLM のグラフ理解能力の向上

辻航平¹ 岡佑依² 西田京介² 坂井優介¹ 上垣外英剛¹ 渡辺太郎¹
¹奈良先端科学技術大学院大学 ²NTT 株式会社 人間情報研究所
 tsuji.kohei.tl1@naist.ac.jp {yui.oka,kyosuke.nishida}@entt.com
 {taro,kamigaito.h,sakai.yusuke.sr9}@is.naist.jp

概要

既存の大規模言語モデルは、グラフ構造の理解が不十分であり、部分的な知識グラフが与えられても推論を誤る場合がある。この能力を学習によって向上させることが望ましいが、実世界の知識グラフの学習データの構築には、大きなアノテーションコストがかかる。そこで、我々は疑似生成した知識グラフとグラフ構造のデータセットを用いた低コストな学習手法を提案する。実験結果から、提案手法は単一ステップの質問応答タスクにおいて十分なグラフ理解能力の向上を確認できた。また複数ステップ理解へ拡張する際の課題と方向性について議論する。

1 はじめに

大規模言語モデル (LLM) が知識に基づいて推論を行う際に求められる能力は、単なる文章理解にとどまらない。対象となる知識がグラフとして与えられることもあり、正確な推論のためにはこれを十分に理解する必要がある。ここでグラフとは、対象を表す点 (ノード) と、それらの関係を表す線 (エッジ) からなるデータ構造であり、関係性を明示的に表現できる。知識グラフ (Knowledge Graph, KG) はその一種で、人物、組織、概念などのエンティティをノードとして、それらの関係を意味付きのエッジで表したものである。例えば、図 1 のように KG に基づく QA タスク (Knowledge Graph Question Answering, KGQA) [1, 2, 3, 4, 5] では、エンティティ間の関係を辿って答えを導く必要がある。また、グラフ上の到達可能性や経路、集合の包含関係といった構造的な性質は、離散数学やアルゴリズムに関する問題設定 [6, 7, 8, 9] としても頻繁に現れる。このように、LLM がグラフを入力として扱い、その構造に基づいて推論する能力は重要である。

しかし現状の LLM は、グラフ構造の把握が得意ではない [6, 7]。ノードやエッジの局所的な情報は

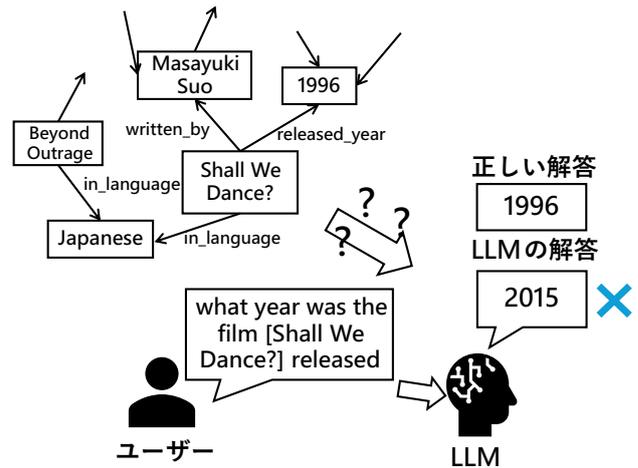


図 1 KGQA の例。LLM はグラフを適切に理解できない。

文章として処理できたとしても、複数ステップの関係追跡では誤りが増えやすい。さらに、単純にエッジを読み取るだけの単一ステップの関係抽出も十分にはこなせない。加えて、部分的な KG が与えられている状況でも、存在しない関係を補完してしまったりすることがある [10]。この課題に対し、LLM のアーキテクチャの改良 [11, 12] や、LLM とグラフニューラルネットワーク (GNN) [13, 14, 15] などのモデルと統合することでグラフ推論能力を補う研究が進められてきた。これらは有効である一方、これらの手法を用いて LLM の性能を安定して引き上げるためには、大量の学習用データが必要になることが多い。それに対して、グラフ構造を含むテキストデータを大規模に準備しようとする、データ収集、整形、アノテーションのコストが高く、必ずしも適用できるとは限らない。

そこで本研究では、実世界の KG から学習データを構築するのではなく、疑似的に生成した KG を用いて、LLM 自身のグラフ理解能力を効率よく獲得させる低コストな学習手法を提案する。具体的には、疑似 KG を生成し、その上でグラフ構造に関する知

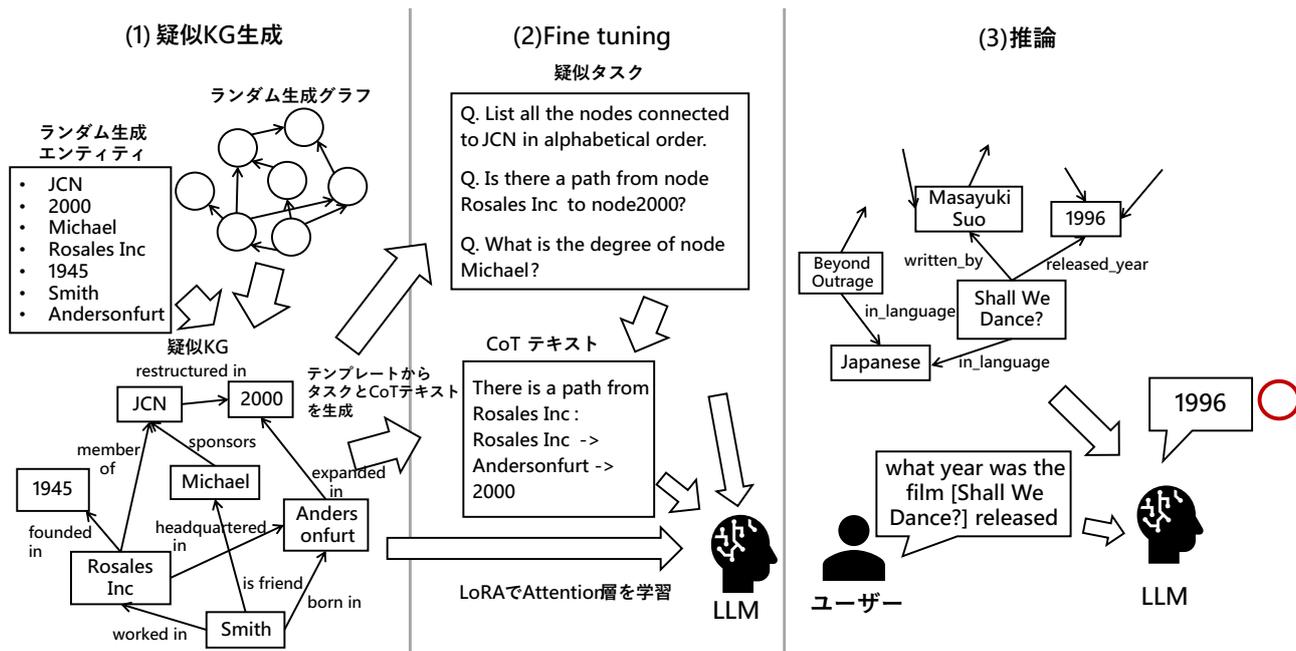


図 2 疑似 KG データによる学習. (1) : 疑似 KG データの生成. (2) : 疑似 KG タスクでの Fine tuning. (3) : KGQA での推論

識を問う 10 種類のタスクを設計して学習に用いる。タスクは、ノードやエッジの数、あるノードのつながり、そのグラフが持っている性質、経路の存在など、グラフそのものやグラフの構造に依存した推論が必要なものになっている。これにより、LLM が表層的なパターンではなく構造そのものを捉えることを狙う。疑似 KG を利用するため、タスク例の自動生成が可能になり、学習データ作成に伴うコストを大幅に抑えられる。

Llama 3.2 3B, 3.1 8B [16], Qwen 3 8B, 13B [17], および Olmo 3 8B [18] の 5 種類の LLM を用いて提案手法を評価した。その結果、学習していない実世界の KGQA タスクのうち、単一ステップの推論で解答できる問題においては精度が大幅に向上することを確認した。しかし、複数ステップの推論が必要な問題においては性能を改善できなかった。一方で、KGQA の訓練データを用いて Fine tuning した場合には、複数ステップの推論が必要な問題に対しても性能が十分向上した。これは、提案手法の限界を示すとともに、現行の LLM アーキテクチャのままでも、適切な学習でグラフ構造の理解能力を獲得できる可能性を示唆している。また、提案手法および実世界の KGQA データセットでの学習はどちらも PIQA [19] や HellaSwag [20] のような一般的な QA タスクの性能を損なわなかった。このことから、既存の LLM の性能を維持したまま追加で LLM にグラフ

理解能力を付与することができると考えられる。

2 疑似 KG データ学習

本研究では、はじめに機械的に KG (疑似 KG) を生成し、それらを用いて追加学習を行う。疑似 KG は自動生成可能なため、グラフ構造データを大量に作成でき、拡張性の面でも利点がある。

2.1 疑似 KG データ生成

疑似 KG は、図 2 (1) のようにノード (エンティティ) とエッジ (関係) からなる有向多関係グラフである。まず、グラフを Erdős-Rényi (ER) モデル [21] を用いてランダムにグラフを生成する (図 2 (1) 右上)。これはノード数 N とエッジの生成確率 p を用いてランダムにグラフを生成するモデルである。提案手法では、多様なグラフを生成するために、ノード数 N およびエッジの生成確率 p は N_{min} から N_{max} および p_{min} から p_{max} をランダムに選択する。その後、疑似エンティティを生成するために、疑似名前生成器¹⁾と乱数に基づく文字列生成を組み合わせ、人物・組織・地名・数字による擬似ノードを N 個生成する (図 2 (1) 左上)。最後に生成したノードをノードラベルとして設定し、エッジにはあらかじめ定義した定型の関係タイプをランダムに割り当てた (図 2 (1) 下)。例えば、人物から

1) <https://fakerjs.dev/>

地名への関係であれば lives in や travels to などを用いた。詳細は Appendix B を参照されたい。

2.2 グラフ理解タスク

生成した疑似 KG に対し、既存の LLM のグラフ構造理解能力を測定するためのテストデータセット [7] を参考にグラフ構造の理解が必要な 10 種類のタスクを設計し、追加学習に用いた (図 2 (2) 上)。各タスクは疑似 KG から自動生成できる。各タスクの具体的な説明は Appendix A に記載している。

2.3 追加学習

追加学習には LoRA [22] を用い、Attention 層のみを学習した (図 2 (2) 下)。グラフ推論では、ノードや関係の対応付けや複数ホップにわたる依存関係の理解が重要となる。本研究では、これらが主に Attention 機構の働きに依存すると考え、Attention 層のみを効率的に適応させる設定を採用した。

2.4 Chain-of-Thought

LLM がグラフの構造を学習しやすくするため、学習データには Chain-of-Thought (CoT) [23] を付与できるようにした (図 2 (2) 中央)。これにより、グラフ構造に基づく推論手順そのものの獲得を促進する。具体的には、各タスクについて、疑似 KG 上での探索手順や中間結論を段階的に記述した推論過程を追加した学習データとして与える。これらはタスク同様にグラフ構造に依存して生成できるため、CoT のデータ作成に追加のコストはかからない。

3 実験設定

データセット 評価データに MetaQA [2] を用いた。MetaQA では 1-hop から 3-hop まで各 hop 数ごとに 1000 件をランダムに選択し用いた。ここで hop とは、質問に答えるために KG 上で辿る必要のある関係の段数を表す。例えば 1-hop は単一の関係から解答できる問題であり、2-hop、3-hop は複数の関係を辿る多段推論を要求する。また、グラフ理解能力の付与が一般的な言語生成能力を損なわないか確認するため、PIQA [19] および HellaSwag [20] を評価に用いた。これにより、提案手法がグラフ関連タスクの性能向上と、非グラフタスクの性能維持を両立できるかを検証する。追加学習に用いる疑似 KG データは、§2.2 で述べた 10 種類のグラフ理解タスクそれぞれについて 1000 件ずつ生成し、合計 10000 件の

表 1 実験結果。太字は各モデル内で最も精度が高かったものを示す。

	Meta QA			PIQA	Hella Swag
	1-hop	2-hop	3-hop		
Llama 3.2 3B					
学習前	0.008	0.129	0.003	0.763	0.558
+CoT	0.462	0.261	0.074	-	-
MetaQA 100	0.624	0.404	0.122	0.763	0.558
MetaQA 10000	0.781	0.789	0.453	0.763	0.558
疑似 KG 学習	0.698	0.075	0.012	0.770	0.555
+CoT	0.464	0.097	0.017	0.768	0.563
Llama 3.1 8B					
学習前	0.052	0.002	0.003	0.792	0.607
+CoT	0.491	0.303	0.066	-	-
MetaQA 100	0.728	0.573	0.219	0.792	0.607
MetaQA 10000	0.795	0.827	0.528	0.792	0.607
疑似 KG 学習	0.774	0.066	0.009	0.793	0.613
+CoT	0.629	0.240	0.045	0.791	0.616
Qwen 3 8B					
学習前	0.448	0.410	0.092	0.764	0.571
+CoT	0.703	0.596	0.208	-	-
MetaQA 100	0.682	0.473	0.159	0.770	0.571
MetaQA 10000	0.828	0.813	0.497	0.774	0.571
疑似 KG 学習	0.735	0.083	0.013	0.775	0.566
+CoT	0.699	0.173	0.028	0.781	0.571
Qwen 3 14B					
学習前	0.619	0.420	0.045	0.803	0.611
+CoT	0.476	0.515	0.229	-	-
MetaQA 100	0.747	0.511	0.163	0.802	0.609
MetaQA 10000	0.858	0.825	0.519	0.802	0.609
疑似 KG 学習	0.774	0.191	0.024	0.794	0.604
+CoT	0.710	0.344	0.074	0.802	0.611
Olmo2 8B					
学習前	0.000	0.000	0.000	0.779	0.558
+CoT	0.001	0.000	0.000	-	-
MetaQA 100	0.014	0.034	0.004	0.779	0.558
MetaQA 10000	0.783	0.747	0.379	0.779	0.558
疑似 KG 学習	0.624	0.064	0.002	0.779	0.557
+CoT	0.565	0.112	0.028	0.776	0.563

学習データを構築した。また、比較のため、MetaQA に対しては MetaQA の訓練データから 100 件および 10000 件を用いて同一条件で学習した設定も用意した。疑似グラフ生成のためのノード数の範囲は $N_{min} = 5$ から $N_{max} = 20$ を、エッジの生成確率の範囲は $p_{min} = 0$ から $p_{max} = 1.0$ を、それぞれ用いた。

モデル 提案手法を適用する LLM として Llama 3.1 8B, Llama 3.2 3B [16], Qwen 3 8B, Qwen 3 14B [17], および Olmo 3 8B [18] を用いた。

プロンプト 入力プロンプトには、ノード集合とエッジ集合を明示的に与えた。ノードはエンティティの一覧として提示し、エッジは (head, relation, tail) のトリプルとして列挙する。ノード情報は、エッジに出現しない孤立ノードや接続の弱いノード

表2 CoT ありで学習した Llama 3.1 8B の KGQA での CoT の定性分析.

質問	CoT	解答	正答
what are the genres of the films directed by [Jerry Lewis]	Arizona Dream, The King of Comedy, Funny Bones, Three on a Couch, The Bellboy, Cinderella, The Errand Boy, The Caddy, The Delicate Delinquent, The Nutty Professor, The Ladies Man, Don't Give Up the Ship, The Disorderly Orderly, The Family Jewels, Hollywood or Bust, Which Way to the Front?, Visit to a Small Planet, The Patsy, 3 Ring Circus, and bd-r are comedies.	Comedy	Drama, Comedy, War
what types are the movies directed by [Anthony Hickox]	Anthony Hickox directed Prince Valiant, Full Eclipse, Last Run, Blast, and Storm Catcher, so they are Action, Adventure, Comedy, Crime, and Thriller.	Action, Adventure, Comedy, Crime, and Thriller	Action, Comedy, Adventure, Thriller, Crime
the movies starred by [Clifford Rose] were written by who	Clifford Rose starred in Marat/Sade, so the writers of Marat/Sade are the answer.	Peter Brook, Peter Weiss, Adrian Mitchell, Geoffrey Skelton, Patrick Magee, Ian Richardson, Marat/Sade, 1967.	Adrian Mitchell, Geoffrey Skelton, Peter Weiss

が入力から欠落することを防ぐために記載する。具体的なプロンプト例は Appendix C に示している。

4 実験結果

実験結果を表 1 に示す。表において、学習前の LLM に対する+CoT は<Think>タグを用いて CoT を強制させた場合の精度であり、疑似 KG 学習に対する+CoT は疑似学習時に CoT ありのプロンプトで学習したことを示す。また、MetaQA 100 と MetaQA 10000 はそれぞれ MetaQA データを 100 件または 10000 件用いて学習した際の精度を示す。

疑似 KG データで追加学習を行った LLM は、学習前の LLM と比較して MetaQA の 1-hop における精度が大幅に向上した。しかし、2-hop および 3-hop では一部の LLM のみわずかに精度が向上するのみで、特に Qwen 3 シリーズでは学習前には正しく解答できていた問題も誤答するようになった。

一方で、MetaQA の訓練データを直接用いて学習した場合には、複数ステップであっても学習前の LLM から精度を大幅に向上した。特に、100 件で学習した場合、すべての LLM において 1-hop では疑似 KG 学習の方が精度が出るものの、2-hop または 3-hop ではほとんどの場合で疑似 KG 学習よりも精度が高い。このことから、疑似グラフ学習は単一ステップの推論で解答できる 1-hop の KGQA の性能を向上できるものの、複数ステップの推論に以前として課題があることがわかった。

また、PIQA および HellaSwag において大きな性能

低下が見られないため、KG についての学習は非グラフ生成能力を維持したまま行えると考えられる。

5 CoT に対する定性分析

CoT ありで学習した Llama 3.1 8B が、MetaQA の 2-hop 問題で生成した思考の例を表 2 に示した。1 つ目の例では、1-hop で到達できる作品は列挙できているものの、2-hop 目での抽出に失敗して不正解になっている。反対に、似た問題で正しく推論できている 2 例目では 1-hop, 2-hop の両方で正しく網羅できたことで正解している。3 つ目の例では、思考過程は正しいものの、Marat/Sade の著者だけでなく、すべてのエッジを解答している。これは、関係に注目するタスクで学習しておらず、関係に基づいた解答を行わなかったことが原因であると考えられる。

6 おわりに

本研究では、LLM のグラフ理解能力を向上させることを目的として、疑似 KG とグラフ構造に関する 10 種のタスクを用いた低コストな追加学習手法を提案した。実験結果から、提案手法は単一ステップの推論で解答できる 1-hop の KGQA の性能を大きく向上できたが、複数ステップの推論では性能向上が得られなかった。要因の一つとして、疑似タスクの中に関係に注目するタスクがないため、複数ステップ推論の際に関係に基づいた解答が難しかったと考えられる。今後はタスクの追加や変更により複数ステップの推論に強い手法に発展させていく。

参考文献

- [1] Xi Ye, Semih Yavuz, Kazuma Hashimoto, Yingbo Zhou, and Caiming Xiong. RNG-KBQA: Generation augmented iterative ranking for knowledge base question answering. In Smaranda Muresan, Preslav Nakov, and Aline Villavicencio, editors, **Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)**, pp. 6032–6043, Dublin, Ireland, May 2022. Association for Computational Linguistics.
- [2] Yuyu Zhang, Hanjun Dai, Zornitsa Kozareva, Alexander J Smola, and Le Song. Variational reasoning for question answering with knowledge graph. In **AAAI**, 2018.
- [3] Yu Gu, Sue Kase, Michelle Vanni, Brian Sadler, Percy Liang, Xifeng Yan, and Yu Su. Beyond iid: three levels of generalization for question answering on knowledge bases. In **Proceedings of the web conference 2021**, pp. 3477–3488, 2021.
- [4] Wen-tau Yih, Matthew Richardson, Chris Meek, Ming-Wei Chang, and Jina Suh. The value of semantic parse labeling for knowledge base question answering. In Katrin Erk and Noah A. Smith, editors, **Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers)**, pp. 201–206, Berlin, Germany, August 2016. Association for Computational Linguistics.
- [5] Aleksandr Perevalov, Dennis Diefenbach, Ricardo Usbeck, and Andreas Both. Qald-9-plus: A multilingual dataset for question answering over dbpedia and wikidata translated by native speakers. In **2022 IEEE 16th International Conference on Semantic Computing (ICSC)**, pp. 229–234, 2022.
- [6] Zihan Luo, Xiran Song, Hong Huang, Jianxun Lian, Chenhao Zhang, Jinqi Jiang, and Xing Xie. Graphinstruct: Empowering large language models with graph understanding and reasoning capability. **CoRR**, Vol. abs/2403.04483, , 2024.
- [7] Bahare Fatemi, Jonathan Halcrow, and Bryan Perozzi. Talk like a graph: Encoding graphs for large language models. In **International Conference on Learning Representations (ICLR)**, 2024.
- [8] Yizhuo Zhang, Heng Wang, Shangbin Feng, Zhaoxuan Tan, Xiaochuang Han, Tianxing He, and Yulia Tsvetkov. Can LLM graph reasoning generalize beyond pattern memorization? In Yaser Al-Onaizan, Mohit Bansal, and Yun-Nung Chen, editors, **Findings of the Association for Computational Linguistics: EMNLP 2024**, pp. 2289–2305, Miami, Florida, USA, November 2024. Association for Computational Linguistics.
- [9] Heng Wang, Shangbin Feng, Tianxing He, Zhaoxuan Tan, Xiaochuang Han, and Yulia Tsvetkov. Can language models solve graph problems in natural language? In **Thirty-seventh Conference on Neural Information Processing Systems**, 2023.
- [10] Yuhang Tian, Dandan Song, Zhijing Wu, Pan Yang, Changzhi Zhou, Jun Yang, Hao Wang, Huipeng Ma, Chenhao Li, and Luan Zhang. CompKBQA: Component-wise task decomposition for knowledge base question answering. In Christos Christodoulopoulos, Tanmoy Chakraborty, Carolyn Rose, and Violet Peng, editors, **Proceedings of the 2025 Conference on Empirical Methods in Natural Language Processing**, pp. 293–309, Suzhou, China, November 2025. Association for Computational Linguistics.
- [11] Chengxuan Ying, Tianle Cai, Shengjie Luo, Shuxin Zheng, Guolin Ke, Di He, Yanming Shen, and Tie-Yan Liu. Do transformers really perform badly for graph representation? **Advances in neural information processing systems**, Vol. 34, pp. 28877–28888, 2021.
- [12] Moritz Pleniz and Anette Frank. Graph language models. In Lun-Wei Ku, Andre Martins, and Vivek Srikumar, editors, **Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)**, pp. 4477–4494, Bangkok, Thailand, August 2024. Association for Computational Linguistics.
- [13] Runjin Chen, Tong Zhao, Ajay Kumar Jaiswal, Neil Shah, and Zhangyang Wang. LLaGA: Large language and graph assistant. In Ruslan Salakhutdinov, Zico Kolter, Katherine Heller, Adrian Weller, Nuria Oliver, Jonathan Scarlett, and Felix Berkenkamp, editors, **Proceedings of the 41st International Conference on Machine Learning**, Vol. 235 of **Proceedings of Machine Learning Research**, pp. 7809–7823. PMLR, 21–27 Jul 2024.
- [14] Duo Wang, Yuan Zuo, Fengzhi Li, and Junjie Wu. LLMs as zero-shot graph learners: Alignment of GNN representations with LLM token embeddings. In **The Thirty-eighth Annual Conference on Neural Information Processing Systems**, 2024.
- [15] Yijun Tian, Huan Song, Zichen Wang, Haozhu Wang, Ziqing Hu, Fang Wang, Nitesh V Chawla, and Panpan Xu. Graph neural prompting with large language models. In **Proceedings of the AAAI Conference on Artificial Intelligence**, Vol. 38, pp. 19080–19088, 2024.
- [16] Aaron Grattafiori, Abhimanyu Dubey, Abhinav Jauhri, Abhinav Pandey, Abhishek Kadian, Ahmad Al-Dahle, Aiesha Letman, Akhil Mathur, Alan Schelten, Alex Vaughan, et al. The llama 3 herd of models, 2024.
- [17] An Yang, Anfeng Li, Baosong Yang, Beichen Zhang, Binyuan Hui, Bo Zheng, Bowen Yu, Chang Gao, Chengen Huang, Chenxu Lv, et al. Qwen3 technical report. **arXiv preprint arXiv:2505.09388**, 2025.
- [18] Team Olmo, Allyson Ettinger, Amanda Bertsch, Bailey Kuehl, David Graham, David Heineman, Dirk Groeneveld, Faeze Brahman, Finbarr Timbers, Hamish Ivison, et al. Olmo 3. **arXiv preprint arXiv:2512.13961**, 2025.
- [19] Yonatan Bisk, Rowan Zellers, Ronan Le Bras, Jianfeng Gao, and Yejin Choi. Piqa: Reasoning about physical commonsense in natural language. In **Thirty-Fourth AAAI Conference on Artificial Intelligence**, 2020.
- [20] Rowan Zellers, Ari Holtzman, Yonatan Bisk, Ali Farhadi, and Yejin Choi. HellaSwag: Can a machine really finish your sentence? In Anna Korhonen, David Traum, and Lluís Màrquez, editors, **Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics**, pp. 4791–4800, Florence, Italy, July 2019. Association for Computational Linguistics.
- [21] PERDdS and A R&wi. On random graphs i. **Publ. Math. Debrecen**, 1959.
- [22] 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 **International Conference on Learning Representations**, 2022.
- [23] Jason Wei, Xuezhi Wang, Dale Schuurmans, Maarten Bosma, Fei Xia, Ed Chi, Quoc V Le, Denny Zhou, et al. Chain-of-thought prompting elicits reasoning in large language models. **Advances in neural information processing systems**, Vol. 35, pp. 24824–24837, 2022.

表3 疑似KG学習で用いる各タスクの定義.

タスク	定義
Cycle check	与えられたグラフに閉路が存在するかどうか
Edge existence	与えられたノード2つはエッジで直接繋がっているか
Node count	与えられたグラフに存在するノードはいくつか
Node degree	与えられたノードはエッジがいくつ繋がっているか
Edge count	与えられたグラフに存在するエッジはいくつか
Connected Nodes	与えられたノードと繋がっている全てのノードを記述
Disconnected Nodes	与えられたノードと繋がっていない全てのノードを記述
Reachability	与えられたノード2つが繋がっているかどうか
Shortest path	与えられたノード2つを繋ぐ最短のパスはどこか
Triangle counting	与えられたグラフ中に三角グラフはいくつか

表4 疑似KGの関係テンプレート.

Head	Tail	関係テンプレート
人名	人名	is friends with, collaborates with
人名	会社	works at, founded
人名	地名	lives in, travels to
人名	数値	was born in, graduated in
会社	人名	employs, appointed
会社	会社	partners with, acquired
会社	地名	is headquartered in, expands to
会社	数値	founded in, launched in
地名	人名	hosts, honored
地名	会社	welcomes, supports
地名	地名	is twinned with, trades with
地名	数値	was established in, expanded in
数値	人名	is the birth year of
数値	会社	is the founding year of
数値	地名	is the establishment year of

プロンプト例

In an undirected graph, (i, r, j) means that node i and node j are connected, with relation r. G describes a graph among nodes 1914, 1927, 1945, 2000, Andersonfurt, Barbarafurt, DKZH, Hernandez-Martin, JBB, JCN, Jonathan Smith, Michael Mcguire, Michael Thomas, North Bethburgh, Ray-Weber, and Rosales Inc. The edges in G are: (DKZH, is a member of, Rosales Inc) (JBB, is a member of, Jonathan Smith) (DKZH, works at, Jonathan Smith) (Hernandez-Martin, works at, Jonathan Smith) (Jonathan Smith, mentors, Michael Thomas) (Barbarafurt, grew up in, Jonathan Smith) (Jonathan Smith, leads, Ray-Weber) (1945, was established in, Andersonfurt) (Andersonfurt, honored, Michael Mcguire) (Andersonfurt, partners with, JBB) (Andersonfurt, supports, JCN) (1914, expanded in, Andersonfurt) (Andersonfurt, supports, Hernandez-Martin) (Andersonfurt, honored, Michael Thomas) (Andersonfurt, supports, Ray-Weber) (1945, is the establishment year of, JBB) (1945, is the expansion year of, JCN) (1914, connects to, 1945) (1945, is the establishment year of, DKZH) (1927, connects to, 1945) (1945, is the restructuring year of, Ray-Weber) (JCN, collaborates with, Michael Mcguire) (1914, was born in, Michael Mcguire) (DKZH, founded, Michael Mcguire) (Michael Mcguire, lives in, North Bethburgh) (Hernandez-Martin, works at, Michael Mcguire) (JBB, partners with, JCN) (1914, was established in, JBB) (2000, hosted events in, JBB) (DKZH, partners with, JBB) (JBB, supports, North Bethburgh) (Hernandez-Martin, supports, JBB) (JBB, supports, Michael Thomas) (Hernandez-Martin, partners with, JCN) (JCN, supports, Michael Thomas) (JCN, partners with, Ray-Weber) (1914, connects to, 2000) (1914, is the expansion year of, DKZH) (1914, is the starting year of, Michael Thomas) (1914, is the expansion year of, Barbarafurt) (2000, is the founding year of, Hernandez-Martin) (2000, is the graduation year of, Michael Thomas) (1927, connects to, 2000) (2000, is the expansion year of, Ray-Weber) (DKZH, is based in, North Bethburgh) (DKZH, partners with, Hernandez-Martin) (DKZH, is led by, Michael Thomas) (Barbarafurt, hosts events in, DKZH) (1927, expanded in, DKZH) (1927, grew by, North Bethburgh) (Hernandez-Martin, appointed, Michael Thomas) (Barbarafurt, studies in, Michael Thomas) (1927, started working in, Michael Thomas) (Michael Thomas, leads, Ray-Weber) (1927, was established in, Barbarafurt) (Barbarafurt, supports, Ray-Weber) (1927, is the founding year of, Ray-Weber).

Q: List all the nodes connected to DKZH in alphabetical order.
A: 1914, 1927, 1945, Barbarafurt, Hernandez-Martin, JBB, JCN, Jonathan Smith, Michael Mcguire, Michael Thomas, North Bethburgh, Rosales Inc.

A グラフ理解タスクの詳細

提案手法で用いたグラフ理解タスクでは表3の10タスクを用いた.

B 疑似KGの関係テンプレート例

提案手法で用いた疑似KGの関係テンプレートのうち一部を表4に示す.

C プロンプト例

提案手法で用いた疑似KGとグラフ理解タスクの実際のLLMへの入力例を右に示す. タスクはConnected Nodesである.