



开放科学
(资源服务)
标识码
(OSID)

基于大语言模型与混合检索增强的教育知识图谱构建与智能问答

刘杰平 夏磊

成都东软学院智能科学与工程学院 成都 611844

摘要: [目的/意义] 教育知识图谱在帮助学习者理解知识结构、规划学习路径等方面扮演着关键角色。然而,其构建过程面临如命名实体识别(NER)和关系抽取(RE)等技术难题。本文提出一种结合大语言模型(LLMs)和混合检索增强生成(Hybrid RAG)技术的框架,旨在优化教育知识图谱的构建及智能问答。[方法/过程] 该框架融合多源数据,遵循OBE教育理念,通过对LLM进行微调,有效提升了NER和RE任务的性能。此外,Hybrid RAG技术进一步增强了问答系统的准确性。[结果/结论] 首先,提出了基于OBE理念的知识图谱构建新视角;其次,构建了Text2RDF数据集,提升了LLM在NER和RE任务的性能;最后,通过整合Vector RAG与Graph RAG的优势,改善了模型在事实检索、多跳推理和信息融合方面的性能。实验结果显示,经过LoRA微调的模型在NER和RE任务上的F1分数显著提高,且Hybrid RAG在多种问答场景中均表现出更高的准确性。

关键词: 大语言模型; 知识图谱; Graph RAG; Hybrid RAG

中图分类号: G35; TP391

Educational Knowledge Graph Construction and Intelligent Question Answering Based on Large Language Models and Hybrid Retrieval-Augmented Generation

LIU Jieping XIA Lei

School of Intelligent Science and Engineering, Chengdu Neusoft University, Chengdu 611844, China

Abstract: [Objective/Significance] The educational knowledge graph plays a crucial role in helping learners understand the structure of knowledge and plan learning paths. However, its construction faces technical challenges such as Named Entity Recognition (NER) and Relation Extraction (RE). This study proposes a framework that combines Large Language Models

基金项目 中国高等教育学会高等教育科学研究规划课题“大数据专业知识图谱构建与智能问答平台研究”(22SZH0305); 全国高等院校计算机基础教育研究会教学研究项目“融合大语言模型的知识图谱构建在人才培养中的应用研究”(2024-AFCEC-219)。

作者简介 刘杰平(1989-), 通信作者, 硕士, 副教授, 主要研究方向为数据分析与挖掘, E-mail: liujieping@nsu.edu.cn; 夏磊(1981-), 博士, 副教授, 主要研究方向为机器学习和智能系统。

引用格式 刘杰平, 夏磊. 基于大语言模型与混合检索增强的教育知识图谱构建与智能问答[J]. 情报工程, 2026, 12(1): 29-39.

(LLMs) and Hybrid Retrieval-Augmented Generation (Hybrid RAG) technology, aiming to optimize the construction of the educational knowledge graph and intelligent question answering. [Methods/Processes] This framework integrates multi-source educational data in accordance with the Outcome-Based Education (OBE) paradigm. Through fine-tuning the LLM, it achieves significant performance improvements in both NER and RE tasks. Additionally, the Hybrid RAG technology further enhances the accuracy of the question answering system. [Results/Conclusions] Firstly, a new perspective for constructing knowledge graphs based on the OBE is proposed; secondly, the development of the Text2RDF dataset, which enhances the performance of LLM in NER and RE tasks; and finally, the integration of the advantages of Vector RAG and Graph RAG, which improves the model's performance in fact retrieval, multi-hop reasoning, and information integration. Experimental results show that the model fine-tuned with LoRA significantly increases the F1 score in NER and RE tasks, and Hybrid RAG demonstrates higher accuracy in various question answering scenarios.

Keywords: LLM; Knowledge Graph; Graph RAG; Hybrid RAG

引言

学习者自主性是现代教育的重要目标之一，但学习者在自主学习过程中普遍面临挑战。研究表明，缺乏明确的学习目标和计划是导致学习困难的关键因素之一^[1]。此外，海量学习资源引发的“知识迷宫”问题，以及未能建立科学的专业知识框架，进一步加剧了学习者的困惑^[2]。

知识图谱 (Knowledge Graph, KG) 是一种结构化的知识表示方法，在教育领域展现出巨大潜力。通过构建教育知识图谱并融入智能问答功能，可以支持学习者自主探索知识体系，规划学习路径，提升学习自主性^[3]。但目前教育知识图谱的构建主要以课程为对象，而人才培养涵盖课程体系、学科竞赛、素质活动等多维教学环节。因此，构建以学科或专业为对象的教育知识图谱更具实际意义。另外，传统的知识图谱构建技术在命名实体识别 (Named Entity Recognition, NER)、关系抽取 (Relation Extraction, RE) 和复杂推理任务中仍面临诸多挑战^[4]。近年来，大语言模型 (Large Language

Model, LLM) 凭借其强大的文本理解和生成能力，为知识图谱构建提供了新思路^[5]。然而，尽管 LLM 在通用任务中表现出色，但在 NER 和 RE 等特定任务中的性能仍显著低于监督学习基线^[6]。

在智能问答方面，基于检索增强生成 (Retrieval-Augmented Generation, RAG) 技术可以提升问答系统的性能。然而，传统 RAG (Vector RAG) 主要通过文本向量化，并基于与用户提问的相似度来检索答案。该方法在处理深层逻辑推理或复杂关系理解时存在局限，更适合直接信息检索而非复杂推理任务^[7]。相比之下，基于知识图谱的增强检索 (Graph RAG) 利用知识图谱的结构化表示，增强了检索信息的深度与上下文关联性，为复杂推理任务提供了新的解决方案。例如，在执行多跳推理时，可以通过知识图谱中的多个节点和边追踪答案，提升了 LLM 在处理多源信息推理任务中的有效性^[8-9]。不过，与 Graph RAG 相比，Vector RAG 在直接信息检索的准确性和效率上更具优势。

针对上述问题，本文提出了一种基于 LLM

与 Hybrid RAG 的教育知识图谱构建框架。该框架以成果导向教育 (Outcome-Based Education, OBE) 理念为指导, 结合在线招聘信息与教育文本等多数据源, 通过微调 LLM 实现高效的命名实体识别与关系抽取, 并通过融合 Vector RAG 和 Graph RAG 的混合增强检索 (Hybrid RAG) 提升基于知识图谱的问答准确性。本文的主要贡献包括以下三点:

(1) 提出了基于 OBE 理念的专业知识图谱构建思路, 弥补了教育领域知识图谱构建的不足;

(2) 构建了用于命名实体识别和关系抽取的数据集 Text2RDF, 提升了 LLM 在 NER 和 RE 任务中的精确率和召回率。该数据集可在阿里巴巴魔搭 (ModelScope) 社区公开下载;

(3) 通过混合增强检索提升了 LLM 在事实检索、多跳推理和多源聚合等任务中的问答准确性。

1 相关研究

1.1 教育领域知识图谱的应用

知识图谱的思想可追溯至 1956 年 Richens 提出的语义网^[10], 其核心是通过网络化结构表达知识实体及其关系。2012 年, 谷歌正式提出知识图谱概念^[3], 该技术逐步成为知识表示与推理的重要工具。在教育领域, 知识图谱的价值得到了连接主义学习理论的支持。该理论认为, 学习是学习者构建认知网络的过程, 其效果依赖于知识节点的优质性与连通性^[11]。教育知识图谱通过显性化知识节点与关联路径, 与学习者认知网络的构建过程高度契合^[12], 为教

育领域的应用提供了理论基础。

近年来, 知识图谱在教育领域的应用研究日益丰富, 涵盖了智慧化教学资源、个性化学习推荐、学习行为建模、智能问答系统等多个方面^[12-15]。例如, Lang 等^[16]提出了结合课程知识图谱的个性化知识点推荐模型, 该模型提取答案记录中的知识点并将其映射到课程知识图谱中, 为学习者推荐个性化的知识点; Zhang 等^[17]提出了一种利用知识图谱进行个性化教育的自适应学习方法, 该方法涉及多维知识图谱框架、基于注意力机制的分类以及利用激活理论的导航路径生成等; Agrawal 等^[18]从非结构化课程材料构建了一个知识图谱, 直观地呈现网络安全中的复杂概念, 促进网络安全教育。此外, 知识图谱具有相互关联的结构和丰富的语义, 可以增强搜索结果和答案的精确度, 以及上下文关联性和深度^[12]。因此, 许多学者基于知识图谱设计了语义搜索、问答和推荐系统。例如, Nair 等^[19]提出了一种结合知识图谱和预训练 BERT 的问答模型; Wang 等^[20]设计了一个集成知识图谱可视化模块的问答系统, 提高了在线学习者获取答案的效率和满意度。

当前教育知识图谱的构建主要基于课程资料, 忽略了学科竞赛、素质活动、招聘需求等数据的整合。为此, 本文提出构建融合企业人才需求、培养方案和课程体系的多源专业知识图谱, 以更全面地支撑人才培养。已有研究者在该方向上进行了初步探索。例如, Yang 等^[21]通过分析毕业要求、课程与知识之间的关系, 构建了以“知识 - 课程 - 毕业要求”为主线的层次化知识图谱; Fettach 等^[22]提出基于知识图谱的教育与就业市场链接框架。不过, 现有探索

仍存在一定的局限：Yang 等^[21]虽然拓展了教育知识图谱的数据维度，但其构建逻辑仍囿于教育系统内部要素的关联，未整合企业用人需求等外部市场因素；而 Fattach 等^[22]在技术实现层面仍主要依赖传统的 RNN 和关联规则挖掘方法，未能充分利用当前知识图谱领域技术的最新进展。

1.2 大语言模型辅助知识图谱构建

知识图谱的构建需要运用多方面的技术，包括知识抽取、知识表示、知识融合、知识推理等^[23]。其中，知识抽取是构建知识图谱的基础，主要包括 NER 和 RE 等。常见的知识抽取方法主要包括基于语言规则和模板、统计机器学习、深度学习等方法^[23]。2022 年，大语言模型的发布为自然语言处理领域带来了更高的效率和更优的性能。与传统的知识抽取方法相比，大语言模型凭借其强大的语义理解能力，能够更好地实现 NER、RE 等任务，并取得显著效果^[24-25]。

在 NER、RE 等任务中，主要通过提示词工程^[6, 26-27]、零样本或少样本学习^[6, 27-29]、监督微调^[30-31]等技术提升大语言模型的性能。例如，Wei 等^[27]提出了一种名为“ChatIE”的两阶段问答框架，基于提示词工程技术，利用 ChatGPT 进行命名实体识别。该框架在六个数据集上的实证结果表明，通过直接提示大语言模型进行命名实体识别具有显著有效性。Li 等^[32]分析了现有关系抽取提示的局限性，并提出了一种名为“总结和提问提示”的新方法。该方法通过递归使用大语言模型将零样本关系抽取输入转换为有效的问答格式。Zhou 等^[31]提出

了一种基于低质量数据集对 ChatGLM3-6B 模型进行微调的 NER 方法，用于建筑文档的信息提取。结果显示，与未经微调的 ChatGLM3-6B 模型相比，该方法的识别准确性和完整性显著提高。

1.3 知识图谱增强大语言模型检索

尽管大语言模型具有强大的自然语言理解与文本生成能力，然而仍存在不可解释性、知识实时性差、幻觉等挑战^[33-34]。为应对这些挑战，RAG 技术被提出。该技术通过语义相似度计算，从外部知识库检索相关文档块来增强大语言模型，有效减少 LLM 与事实不符的内容生成^[33]。Vector RAG 通过文本向量化和相似度匹配检索答案，擅长直接信息检索，但在深层逻辑推理、复杂关系理解上存在局限；而 Graph RAG 依托知识图谱中实体与关系的结构化表达，强化了检索信息的深度和上下文关联性，能支持多跳推理，助力大语言模型理解复杂语义关系，提升多信息源综合推理的有效性，同时减少模型幻觉。例如，Guo 等^[35]提出了一种名为 Knowledge Navigator 的框架，利用知识图谱对大语言模型实现准确且可解释的多跳推理，该框架提高了大语言模型在问答方面的性能；Soman 等^[36]利用大规模生物医学知识图谱，实现了基于知识图谱的检索增强生成框架，在不影响准确性的情况下减少 50% 以上的 Token 消耗；Xu 等^[37]通过将 RAG 与知识图谱相结合，不仅提高了客服系统的检索准确性和回答质量，还将每个问题的平均解决时间缩短了 28.6%；尽管 Graph RAG 在处理深层逻辑推理或复杂关系理解时更具优势，Vector RAG 在直接信息检

索的准确性和效率上表现更佳。因此，将二者结合可以为大语言模型提供更加全面可靠的检索问答能力。Sarmah 等^[38]在金融领域进行了尝试，通过 Hybrid RAG 增强了问答系统从金融文档中提取信息并生成准确且上下文相关答案的能力。

2 框架设计

本节阐述基于大语言模型与混合检索增强技术的教育知识图谱构建及智能问答框架，如图 1 所示。该框架包含两个核心阶段：基于大语言模型的知识图谱构建和基于混合检索增强的智能问答系统。

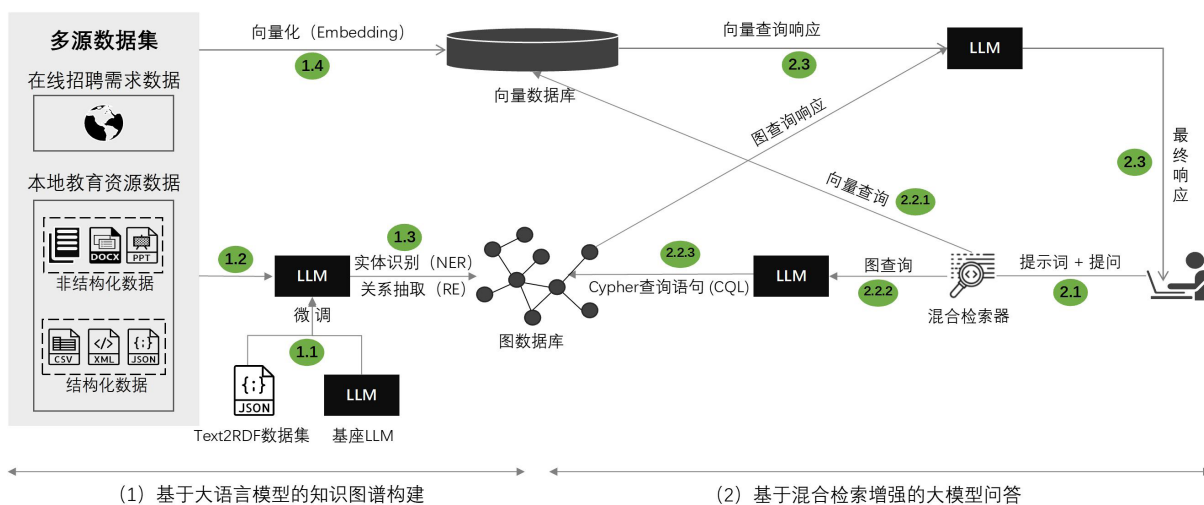


图 1 融合大语言模型与混合检索增强技术的教育知识图谱构建及智能问答系统框架

2.1 基于大语言模型的知识图谱构建

资源描述框架 (Resource Description Framework, RDF) 是知识图谱的标准表示方法之一，采用 (主体, 谓词, 客体) 三元组结构，例如：(Albert Einstein, WinnerOf, Nobel Prize)^[3]。针对基础 LLM 在 NER 和 RE 任务中的性能局限，本文通过自建 Text2RDF 数据集对基础 LLM 进行微调，实验表明微调后模型在精确率与召回率上均有显著提升。

此外，针对当前教育知识图谱构建的不足，本框架采用多源数据融合策略，将企业招聘需求作为关键数据，与人才培养方案、课程大纲、教学资料等共同构成知识源。通过微调后的 LLM 对多源数据进行 NER 和 RE 处理，输出结

构化 RDF 三元组并存储为 JSON 格式，如图 1 中 1.3 所示。最终，知识数据导入 Neo4j 等图数据库，而原始文本经分块、嵌入向量化后存入向量数据库，如图 1 中 1.4 所示。

2.2 基于混合检索增强的智能问答

在检索增强技术中，Vector RAG 与 Graph RAG 具有互补优势：前者支持精确图模式匹配和多跳推理，后者具备高效查询与灵活适配特性，如图 1 中 2.1 所示，本框架的混合检索流程融合了 Vector RAG 和 Graph RAG，具体包含：图检索路径：将用户查询转换为 Cypher 查询语言 (Cypher Query Language, CQL) 执行图数据库检索，如图 1 中 2.2.2 所示；向量检索路径：直接在向量数据库执行相似性检索，如图 1 中

2.2.1 所示。最后，双路径结果与用户查询经提示词工程整合后，由问答 LLM 生成最终响应。

3 实验与分析

3.1 实验说明

实验以大数据管理与应用专业为研究对象；实验环境配置为 Ubuntu 22.04 LTS，内存为 755GB，GPU 为 4 块 NVIDIA A800（显存 80GB），CUDA 版本为 12.0。NER 和 RE 任务使用的大语言模型为 Qwen2-7B 和 GLM4-

9B，检索问答任务使用的大语言模型为 GLM4-Plus。向量数据库采用 ChromaDB 0.6.0，图数据库采用 Neo4j 4.4.39。

3.2 实验步骤

3.2.1 微调数据集构建

由于缺乏教育领域的 Text2RDF 数据集，本文开发了专用的 Text2RDF 标注工具。然后从课程介绍、理论知识、学科竞赛、岗位需求等数据中选取 1000 段文本，通过人工标注生成了 7228 条 Text2RDF 微调数据。示例如下：

```
{ "input": "Hive 数据仓库课程在第 4 学期开设，总学时为 48 课时。该课程主要教授 Hive 的使用。Hive 是数据仓库工程师必须熟练掌握的软件工具。",
  "output": { "spo_1": { "subject": { "name": "Hive 数据仓库", "type": "课程", "attributes": { "学期": "4", "学时": "48" } }, "predicate": { "name": "包含", "type": "", "attributes": {} }, "object": { "name": "Hive", "type": "软件工具", "attributes": {} } }, "spo_2": { "subject": { "name": "数据仓库工程师", "type": "岗位", "attributes": {} }, "predicate": { "name": "熟练掌握", "type": "", "attributes": {} }, "object": { "name": "Hive", "type": "软件工具", "attributes": {} } } }
```

3.2.2 大语言模型微调

在本地部署 Qwen2-7B 和 GLM4-9B 模型，利用 LLaMa-Factory 框架和 Text2RDF 数据集进行 LoRA 微调，得到 Qwen2-7B-LoRA 和 GLM4-9B-LoRA 模型。由于 Text2RDF 需要模型理解结构化语义，过大的学习率可能导致语

义关系建模不稳定。因此，在 LLaMA-Factory 框架微调中将学习率（learning_rate）设置为 2e-5，训练轮次（num_train_epochs）为 10，其余参数保持默认。

微调后的模型能够高效完成 NER 和 RE 任务，并输出结构化 JSON 结果。以下为示例对比：

```
# Base LLM (Qwen2-7B 或 GLM4-9B)
input: William 是一名 35 岁的男性教授，目前教授 Hive 数据仓库课程。
output: William, 人名, 男;35, 年龄;Hive 数据仓库, 课程;
# 微调后的 LLM (GLM4-9B-LoRA 或 Qwen2-7B-LoRA)
{ "input": "William 是一名 35 岁的男性教授，目前教授 Hive 数据仓库课程。", "output": { "spo_1": { "subject": { "name": "William", "type": "教师", "attributes": { "性别": "男", "年龄": "35" } }, "predicate": { "name": "教授", "type": "", "attributes": {} }, "object": { "name": "Hive 数据仓库", "type": "课程", "attributes": {} } } }
```

在微调之前，基础大语言模型（Base LLM）仅能识别实体，很难有效识别实体之间的关系。经过微调后，模型不仅能够准确识

别实体间的关系，还能完整地提取实体的属性信息。此外，模型输出的 JSON 格式的三元组形式更加规范，为后续知识图谱的构建提供了

便利。

3.2.3 知识图谱构建

本文基于 OBE 理念构建大数据专业知识图谱，如图 2 所示，涵盖课程、知识、软件工具、岗位、职责、素养六类本体，明确了课程对知识的包含关系、对软件工具的训练关系，以及岗位对知识的要求掌握、对工具熟练使用、对素养的具备、对职责的对应等核心关联，实现了教育要素与职业需求的系统整合，为学习者提供了面向岗位需求的专业学习框架。

通过整合该专业课程体系、课程大纲、教学教案以及招聘网站中相关招聘需求等文本数据，利用微调后的大语言模型，从这些文本数据中进行实体识别和关系抽取，构建了该专业

知识图谱。目前，该知识图谱包含超过 14000 个实体和 20000 多条关系，该专业局部的知识图谱如图 3 所示，左图显示了数据分析师岗位所需的软件工具，以及这些工具在哪些课程中提及。右图进一步展示了这些课程所包含的理论知识点。

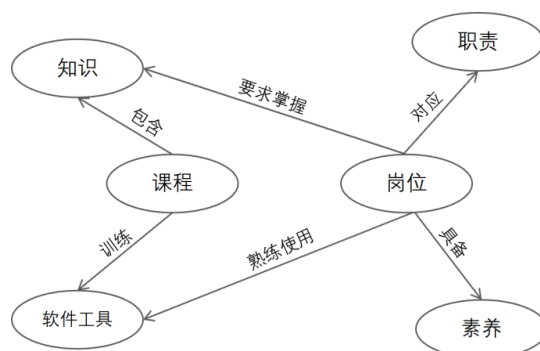


图 2 大数据管理与应用专业知识图谱的本体设计




图 3 大数据管理与应用专业知识图谱(局部)

3.2.4 混合检索问答

本文基于 LangChain 框架构建了混合检索问答：首先对专业文本数据进行加载，采用 RecursiveCharacterTextSplitter 类进行智能分块；然后使用 ZhipuAI 的 Embedding-3 模型生成向量表示，并将数据存储至 ChromaDB 向量数据库；最终实现混合检索器与智能问答功能，并

通过 Streamlit 开发了交互式 Web 应用。

以下是不同 RAG 问答的示例，其中 d1、d2、d3 分别表示不同的文本文件。可以看出，Hybrid RAG 结合了 Vector RAG 和 Graph RAG 的优势，因此，其回答的准确性和灵活性总体更好。

d1: …Hive 数据仓库这门课程在第 4 学期

开设,共3学分,主要讲授数据仓库环境搭建,数据仓库建模与分析,HQL代码编写及Hive、Sqoop、Hadoop等相关工具的使用…;

d2:…全国大学生大数据技能竞赛要求选手掌握Linux、Hadoop、Hive、Sqoop、

Mysql、xshell等软件工具…;

d3:…大数据工程师熟练掌握Java、Scala、Shell、Linux,熟悉Sqoop、Flume等ETL工具,熟悉Hadoop,Spark,Hive等大数据处理、存储、分析平台的原理和使用…。

表1 三种检索增强生成问答效果的示例对比

Vector RAG	Graph RAG	Hybrid RAG
Q: Hive 数据仓库课程要求掌握哪些软件工具? A: 要求掌握 Hive、Sqoop、Hadoop 等工具。	Q: Hive 数据仓库课程要求掌握哪些软件工具? A: 要求掌握 Hive、Sqoop、Hadoop 等工具。	Q: Hive 数据仓库课程要求掌握哪些软件工具? A: 要求掌握 Hive、Sqoop、Hadoop 等工具。
Q: Hive 这门课程要求掌握哪些软件工具? A: 要求掌握 Hive、Sqoop、Hadoop 等工具。	Q: Hive 这门课程要求掌握哪些软件工具? A: 没有查询到 Hive 这个课程节点的信息。	Q: Hive 这门课程要求掌握哪些软件工具? A: 要求掌握 Hive、Sqoop、Hadoop 等工具。
Q: 我想从事大数据工程师相关岗位,哪些课程和竞赛对我来说更重要? A: 我无法从本地向量数据库中检索到相关信息。	Q: 我想从事大数据工程师相关岗位,哪些课程和竞赛对我来说更重要? A: Hive 数据仓库和全国大学生大数据技能竞赛的知识与大数据工程师技能要求类似,你应该学习好这些课程。	Q: 我想从事大数据工程师相关岗位,哪些课程和竞赛对我来说更重要? A: Hive 数据仓库和全国大学生大数据技能竞赛的知识与大数据工程师技能要求类似,你应该学习好这些课程。

3.3 实验分析

为了进一步评估框架的性能,我们进行了量化分析。本文对两个主流大语言模型(Qwen2-7B和GLM-4-9B)进行了微调,并对比

了微调前后模型在NER和RE任务中的性能表现,包括精确率(Precision, P)、召回率(Recall, R)和F1值(F1 Score)。统计结果如表2所示。

表2 大语言模型微调在命名实体识别与关系抽取任务中的性能对比

Model	NER			RE		
	P	R	F1	P	R	F1
Qwen2-7B	76.00%	86.11%	80.74%	84.24%	80.00%	82.07%
Qwen2-7B-LoRA	93.47%	88.05%	90.68%	92.56%	86.58%	89.47%
GLM-4-9B	86.67%	89.55%	88.09%	83.94%	92.21%	87.88%
GLM-4-9B-LoRA	94.56%	91.29%	92.90%	96.10%	90.94%	93.45%
BERT-CRF	89.05%	87.23%	88.13%	-	-	-
RoBERTa-CRF	91.80%	88.82%	90.29%	-	-	-
SpanBERT	92.13%	89.16%	90.62%	89.34%	88.70%	89.02%

从统计结果可以看出,在NER任务中,Qwen2-7B和GLM-4-9B模型的表现均较为优异,但经过LoRA微调后,模型性能显著提升。

Qwen2-7B-LoRA模型的F1值较Qwen2-7B模型提升了9.94个百分点,而GLM-4-9B-LoRA模型的F1值较GLM-4-9B模型提升了4.81个

百分点。在 RE 任务中，LoRA 微调后的模型同样表现出显著优势。Qwen2-7B-LoRA 模型的 F1 值较 Qwen2-7B 模型提升了 7.4 个百分点，而 GLM-4-9B-LoRA 模型的 F1 值较 GLM-4-9B 模型提升了 5.57 个百分点。

此外，本文还对比了经典的 NER 和 RE 模型，结果表明经过训练的 BERT 系列模型在 F1 值指标上优于未经微调的大语言模型但逊色于经过微调的大语言模型。值得注意的是，本研究仅对 7B 和 9B 的小规模大语言模型进行了微调实验，而随着大语言模型技术的快速发展和模型参数规模的持续扩大，其性能表现呈现出显著的提升趋势。此外相较于经典模型，大语言模型能够通过端到端方式同时完成 NER 和 RE 任务，并且通过提示词工程等技术可便捷地实现实体消歧、实体属性提取等扩展功能，同时代码实现复杂度显著降低而开发效率大幅提升。因此，在 NER 和 RE 等自然语言处理任务中，LLM 在性能表现和运行效率方面均展现出明显的优势。

最后，我们测试了三种不同的 RAG 技术在三种不同应用场景中的问答效果，并通过人工评分的方式对回答的准确性进行评估。统计结果如表 3 所示。

表 3 不同场景下三种检索增强生成问答策略的准确性评估

	Vector RAG	Graph RAG	Hybrid RAG
事实检索查询	0.892	0.878	0.912
多跳推理	0.790	0.871	0.894
多源聚合查询	0.747	0.856	0.873

从统计结果可以看出，事实检索查询更依赖于文本的语义匹配，而向量检索在语义相似

度计算方面具有显著优势，因此在该场景下，Vector RAG 表现更为突出。相比之下，图结构能够更好地捕捉实体和关系之间的复杂关联，从而支持多跳推理，并能够更有效地表示和融合来自不同来源的异构信息。因此，在多跳推理和多源聚合查询场景中，Graph RAG 展现出更强的性能。而 Hybrid RAG 通过结合 Vector RAG 和 Graph RAG 的优势，在语义匹配、复杂推理以及多源信息整合等方面实现了全面优化，因此在三种场景中均表现最优。

4 结论

本文以教育知识图谱为研究对象，提出了一种结合 LLM 和 Hybrid RAG 技术构建教育知识图谱和智能问答的框架。该框架整合了在线招聘信息和教育文本等多源数据，通过微调 LLM 实现了高效的命名实体识别和关系抽取及智能问答。

本文的贡献主要体现在三个方面：首先，提出了基于 OBE 理念的专业知识图谱构建理念，为教育领域知识图谱的构建提供了新的视角；其次，构建并应用 Text2RDF 数据集，显著提高了 LLM 在命名实体识别和关系抽取任务中的性能，包括精确率和召回率；最后，通过引入融合 Vector RAG 和 Graph RAG 的 Hybrid RAG 技术，进一步提升了 LLM 在事实检索、多跳推理和多源信息聚合等问答任务中的准确性。

然而，本文仍存在一些局限性。首先，当前框架对 Vector RAG 与 Graph RAG 检索结果的融合处理采用直接合并策略，尚未考虑针对

结果冲突的自动化仲裁机制；其次，知识图谱本体设计主要基于岗位需求和课程数据，尚未充分纳入学科竞赛、专业认证等多元化学习要素。未来研究需着重优化混合检索的冲突解算法，并扩展知识图谱的本体覆盖范围，以更好地满足个性化学习需求。

参考文献

- [1] STUDENSKA A. Individual traits, environmental variables and students' perceptions of autonomous learning difficulty[J]. *European Proceedings of Social and Behavioural Sciences*, 2017(19): 460-475.
- [2] 范秀, 张莉超. 大学生学习困难的心理成因及对策的研究[J]. *科学咨询*, 2020(45): 78.
- [3] JI S, PAN S, CAMBRIA E, et al. A Survey on knowledge graphs: representation, acquisition, and applications[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 33(2): 494-514.
- [4] PENG C, XIA F, NASERIPARSA M, et al. Knowledge graphs: opportunities and challenges[J]. *Artificial Intelligence Review*, 2023, 56(11): 13071-13102.
- [5] ZHU Y, WANG X, CHEN J, et al. LLMs for knowledge graph construction and reasoning: recent capabilities and future opportunities[J]. *World Wide Web*, 2024, 27(5): 58.
- [6] WANG S, SUN X, LI X, et al. GPT-NER: named entity recognition via large language models[C]// *Findings of the Association for Computational Linguistics: NAAL 2025*. 2025: 4257-4275.
- [7] EDGE D, TRINH H, CHENG N, et al. From local to global: a graph RAG approach to query-focused summarization[J]. (2024-04-24) [2024-08-23]. arXiv:2404.16130.
- [8] MATSUMOTO N, MORAN J, CHOI H, et al. KRAGEN: a knowledge graph-enhanced RAG framework for biomedical problem solving using large language models[J]. *Bioinformatics*, 2024, 40(6): btac353.
- [9] SANMARTIN D. KG-RAG: Bridging the gap between knowledge and creativity[J]. (2024-05-20) [2024-08-21]. arXiv:2405.12035.
- [10] RICHENS R H. Preprogramming for mechanical translation[J]. *Mechanical Translation and Computational Linguistics*, 1956, 3(1): 20-25.
- [11] LIN J, KE Q, HUANG Z, et al. Dynamic generation of subject knowledge graph and its application in resources intelligent organization[J]. *Journal of Distance Education*, 2022, 40(4): 23.
- [12] ABU-SALIH B, ALOTAIBI S. A systematic literature review of knowledge graph construction and application in education[J]. *Heliyon*, 2024, 10(3): e25383.
- [13] HOU Y, LIU B, FAN Q, et al. Research on the application mode of knowledge graph in education[C]// *Proceedings of the 2023 6th International Conference on Educational Technology Management*. 2023: 215-220.
- [14] LI H, ZHONG B. Educational knowledge graph: research progress and future development-analysis of articles published in core Chinese Journals from 2013 to 2023[J]. *Computer Engineering*, 2024, 50(7): 1-12.
- [15] QU K, LI K C, WONG B T M, et al. A survey of knowledge graph approaches and applications in education[J]. *Electronics*, 2024, 13(13): 2537.
- [16] LANG Y, WANG G. Personalized knowledge point recommendation system based on course knowledge graph[C]// *Journal of Physics: Conference Series*. IOP Publishing, 2020, 1634(1): 012073.
- [17] ZHANG S, WANG X, MA Y, et al. An adaptive learning method based on knowledge graph[J]. *Frontiers in Educational Research*, 2023, 6(6): 112-115.
- [18] AGRAWAL G, DENG Y, PARK J, et al. Building knowledge graphs from unstructured texts: applications and impact analyses in cybersecurity Education[J]. *Information*, 2022, 13(11): 526.
- [19] NAIR L S, SHIVANI M K. Knowledge graph based question answering system for remote school education[C]// *2022 International Conference on Connected Systems & Intelligence*. IEEE, 2022: 1-5.

- [20] WANG X, FAN X. Research and design of knowledge graph-based Q&A and visualization system for online learners[C]// Society for Information Technology & Teacher Education International Conference. Association for the Advancement of Computing in Education, 2023: 958-962.
- [21] YANG Y, CHEN S, ZHU Y, et al. Knowledge graph empowerment from knowledge learning to graduation requirements achievement[J]. Plos One, 2023, 18(10): e292903.
- [22] FETTACH Y, GHOGHO M, BENATALLAH B. Knowledge graphs in education and employability: a survey on applications and techniques[J]. IEEE Access, 2022(10): 80174-80183.
- [23] 张吉祥, 张祥森, 武长旭. 知识图谱构建技术综述[J]. 计算机工程, 2022, 48(3): 23-37.
- [24] WAN Z, CHENG F, MAO Z, et al. GPT-RE: In-context learning for relation extraction using large language models[C]// Proceedings of the 2023 Conference on Empirical Methods in Natural Language Processing. 2023: 3534-3547.
- [25] XU D, CHEN W, PENG W, et al. Large language models for generative information extraction: a survey[J]. Frontiers of Computer Science, 2024, 18(6): 186357.
- [26] ASHOK D, LIPTON Z C. PromptNER: Prompting for Named Entity Recognition[J]. (2023-05-25) [2025-02-10]. arXiv:2305.15444.
- [27] WEI X, CUI X, CHENG N, et al. ChatIE: zero-shot information extraction via chatting with ChatGPT[J]. (2023-02-20) [2024-12-17]. arXiv:2302.10205.
- [28] LI G, WANG P, KE W. Revisiting large language models as zero-shot relation extractors[C]// Findings of the Association for Computational Linguistics: EMNLP 2023. 2023: 6877-6892.
- [29] SAINZ O, GARCÍA-FERRERO I, AGERRI R. GOLLIE: annotation guidelines improve zero-shot information-extraction[J]. (2023-10-16) [2025-02-10]. arXiv:2310.03669.
- [30] WANG C, LIU X, CHEN Z, et al. DeepStruct: pretraining of language models for structure prediction[C]// Findings of the Association for Computational Linguistics, 2022: 803-823.
- [31] ZHOU J, MA Z. Named entity recognition for construction documents based on fine-tuning of large language models with low-quality datasets[J]. Automation in Construction, 2025(174): 106151.
- [32] LI G, WANG P, KE W. Revisiting large language models as zero-shot relation extractors[C]// Findings of the Association for Computational Linguistics. 2023: 6877-6892.
- [33] GAO Y, XIONG Y, GAO X, et al. Retrieval-augmented generation for large language models: a survey[J]. (2023-12-19) [2024-08-11]. arXiv:2312.10997.
- [34] ZHAO P H, ZHANG H L, YU Q H, et al. Retrieval-augmented generation for AI-Generated content: a survey[J]. Data Science and Engineering, 2026, 11(1): 1-29.
- [35] GUO T, YANG Q, WANG C, et al. Knowledgenavigator: leveraging large language models for enhanced reasoning over knowledge graph[J]. Complex & Intelligent Systems, 2024, 10(5): 7063-7076.
- [36] SOMAN K, ROSE P W, MORRIS J H, et al. Biomedical knowledge graph-optimized prompt generation for large language models[J]. Bioinformatics, 2024, 40(9): btae560.
- [37] XU Z, CRUZ M J, GUEVARA M, et al. Retrieval-augmented generation with knowledge graphs for customer service question answering[C]// Proceedings of the 47th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2024: 2905-2909.
- [38] SARMAH B, MEHTA D, HALL B, et al. Hybrid RAG: integrating knowledge graphs and vector retrieval augmented generation for efficient information extraction[C]// Proceedings of the 5th ACM International Conference on AI in Finance. 2024: 608-616.

(责任编辑: 张运良)