doi:10.3772/j.issn.2095-915x.2025.03.006

基于大语言模型的实体关系抽取研究综述

王展[1] 漆桂林[1,5] 高影繁[2,5] 王莉军[2,5] 周禹安[3] 梅书睿[4]

1. 东南大学计算机科学与工程学院 南京 211189；
2. 中国科学技术信息研究所 北京 100038；
3. 陕西科技大学电子信息与人工智能学院 西安 710016；
4. 阿德莱德大学数学科学学院 阿德莱德 5005；
5. 富媒体数字出版内容组织与知识服务重点实验室 北京 100038

开放科学（资源服务）标识码（OSID）

摘要：[目的 / 意义] 针对实体关系抽取这一文本挖掘和信息抽取的核心任务，探讨其在文本建模中自动识别实体间语义关系的应用与挑战。传统技术在少样本场景下效果受限，无法满足复杂任务需求。近年来，基于大语言模型（LLMs）的实体关系抽取技术因其强大的泛化能力和低监督数据依赖，成为研究的前沿。[方法 / 过程] 系统综述了大语言模型在实体关系抽取中的应用，涵盖命名实体识别、关系抽取及实体关系联合抽取三大任务。重点分析了模型的应用框架、关键技术和在不同任务中的表现。同时，结合现有研究，展望了实体关系抽取的数据增强等领域的发展潜力。[结果 / 结论] 大语言模型在实体关系抽取中展现了强大的性能，尤其在低资源场景下显著降低了对标注数据的依赖，拓宽了技术的适用范围。

关键词：实体关系抽取；大语言模型；命名实体识别

中图分类号：G35；TP391

A Review of Entity Relation Extraction Based on Large Language Models

WANG Zhan[1] QI Guilin[1,5] GAO Yingfan[2,5] WANG Lijun[2,5] ZHOU Yuan[3] MEI Shurui[4]

1. School of Computer Science and Engineering, Southeast University, Nanjing 211189, China;
2. Institute of Scientific and Technical Information of China, Beijing 100038, China;
3. College of Electronic Information and Artificial Intelligence, Shaanxi University of Science and Technology, Xi'an 710016, China;
4. School of Mathematical Sciences, The University of Adelaide, Adelaide 5005, Australia;
5. Key Laboratory of Content Organization and Knowledge Services for Rich Media Digital Publishing, Beijing 100038, China

基金项目 2024 年富媒体数字出版内容组织与知识服务重点实验室开放基金“知识图谱增强大模型技术研究”（ZD2024-04/01）。

作者简介 王展（1998-），博士研究生，主要研究方向为大模型、关系抽取；漆桂林（1977-），博士，教授，主要研究方向为人工智能、知识图谱、知识挖掘、大数据，E-mail：gqi@seu.edu .cn；高影繁（1974-），博士，研究员，主要研究方向为智能文本分析；王莉军（1978-），博士，副研究员，主要研究方向为数据挖掘、智能检索；周禹安（2003-），本科生，主要研究方向为计算机科学与技术；梅书睿（2003-），本科生，主要研究方向为数学与应用数学。

引用格式 王展 , 漆桂林 , 高影繁 , 等 . 基于大语言模型的实体关系抽取研究综述 [J]. 情报工程 , 2025, 11(3): 68-77.

Abstract: [Objective/Significance] This study focuses on entity relation extraction, a core task in text mining and information extraction, to explore its applications and challenges in modeling text and automatically identifying semantic relationships between entities. Traditional methods show limited effectiveness in low-resource scenarios and fail to meet the demands of complex tasks. Recently, entity relation extraction techniques based on large language models (LLMs) have emerged as a research frontier due to their strong generalization capabilities and low reliance on supervised data. [Methods/Processes] This paper systematically reviews the applications of LLMs in entity relation extraction, covering three main tasks: named entity recognition, relation extraction, and joint entity-relation extraction. It focuses on analyzing the application frameworks, key techniques, and performance of models across different tasks. Additionally, it discusses potential developments in data augmentation on existing research. [Results/Conclusions] LLMs demonstrate strong performance in entity relation extraction, particularly in significantly reducing dependency on annotated data in low-resource scenarios, thereby expanding the applicability of the technology.
Keywords: Entity Relation Extraction; Large Language Models; Named Entity Recognition

引言

在大数据时代，海量非结构化文本中蕴含着丰富的信息资源，信息抽取（IE）技术应运而生，核心任务包括命名实体识别（NER）、关系抽取（RE）与事件抽取。近年来，随着大语言模型（LLMs）如 BERT、GPT-3、GPT-4 的迅速发展，信息抽取性能得到了显著提升，形成了新的研究范式。

基于深度神经网络（DNN）和预训练语言模型（PLM）的方法通常包括基于流水线的抽取方法和实体关系联合抽取方法。前者将实体识别与关系抽取分开进行，后者则在统一框架中同时建模。近年来，少样本关系抽取方法在多个公开基准数据集上表现优异 [1]。LLMs 利用大规模未标注语料预训练，具有强大的迁移能力，在低资源、少样本或零样本设置中展现出良好性能，大幅降低了标注成本。

尽管如此，当前方法仍面临挑战，如对大规模标注数据的依赖，以及在新型或未见关系上的泛化能力不足。已有综述虽对 IE 技术有所总结，但大多未系统探讨基于 LLMs 的最新进展、挑战与趋势。例如，有的综述关注逆向工程技术，强调 OIE 和远程监督，而忽略 LLMs 在 IE 中的应用；有的仅涉及基于结构化数据的传统方法，未涵盖 LLMs 的最新研究 [2]；也有综述仍以规则或传统机器学习方法为主，未能深入分析 LLMs 技术 [3]。

为弥补这一空缺，本文从任务层级角度出发，划分为命名实体识别、关系抽取和实体关系联合抽取 3 类，并进一步基于关键技术进行系统梳理。主要贡献包括：

（1）针对按层级划分的不同任务，介绍近年来基于大语言模型的实体关系抽取方法；

（2）整理常用数据集和评价指标，总结不同方法的性能差异；

（3）基于前沿研究，提出未来研究方向，包括长文本与跨句关系建模方法、实体关系抽取的数据增强等。

总体而言，本文全面回顾了基于大语言模型的实体关系抽取研究，在表 1 中总结现有成果，分析不同任务中模型表现，指出其局限性并展望未来研究方向。

doi:10.3772/j.issn.2095-915x.2025.03.006

表 1　实体关系抽取方法分类与参考文献对照表

研究	年份	分类		
		命名实体识别	关系抽取	实体关系联合抽取
GPT-RE[1]	2023		√	
LLM-DA[4]	2024	√		
REPLM[5]	2024		√	
SLCoLM[6]	2024		√	
MetaNER[7]	2023	√		
RT[8]	2024	√		
MICRE[9]	2024		√	
AutoRE[10]	2024	√	√	
HGERE[11]	2023			√
TERS[12]	2024			√
LACE[13]	2023		√	
RAG4RE[14]	2024		√	
LTNER[15]	2024	√		
ATG[16]	2024			√
FEW-NERD[17]	2021	√		
MELM[18]	2022	√		
SLIMER[19]	2024		√	
CODEIE[20]	2023	√	√	√
GoLLIE[21]	2024	√	√	√

1　命名实体识别

1.1　命名实体识别的概念与发展

命名实体识别（NER）是从非结构化文本中识别并分类具有特定意义的实体，如人名、地名、组织名、时间和数值等，是信息抽取中的核心任务之一，为关系抽取和事件抽取等任务奠定基础。

早期的 NER 方法主要基于规则和词典，依赖人工构建的规则和预定义词汇表，尽管在特定领域表现良好，但缺乏通用性和鲁棒性。随着机器学习的引入，隐马尔可夫模型（HMM）和条件随机场（CRF）成为主流，通过上下文信息提高了实体识别精度。然而，这些方法仍然依赖大量手工标注数据，且对数据质量敏感。近年来，基于大语言模型的深度学习方法通过自动特征学习和迁移学习显著提高了 NER 的精度和鲁棒性。

1.2　基于大语言模型的命名实体识别

1.2.1　数据增强

尽管数据增强技术有效提升了 NER 模型在低资源场景下的表现，但目前主流方法仍存在一定局限性。现有方法多采用表层改写策略，如上下文重写、同义替换等，缺乏对实体语义多样性的深度建模，容易引入冗余或语义不一致的数据，从而影响模型学习的稳定性和泛化能力。

数据增强技术通过生成更多的训练数据来提升模型的泛化能力，特别是在低资源场景下表现突出。其原理是通过对现有数据进行变换或重写，增加训练数据的多样性。LLM-DA 方法利用大语言模型的生成能力，通过上下文重写和噪声注入来模拟不同语言变体，这种方法增加了训练数据的多样性，提高了模型的泛化能力，尤其在跨领域和低资源环境下展现出显著优势[4]。MELM 方法通过掩码语言建模技术，为低资源 NER 任务提供了一个有效的数据增强策略[18]。

1.2.2　上下文学习

上下文学习的主要思路是通过注入任务相关的上下文信息或提示，增强模型对语境的理解。元函数预训练算法通过在预训练阶段将

NER 任务的上下文知识嵌入模型，使得模型能够在少样本条件下识别出新类型的实体 [22]。SLIMER 方法通过在提示中加入定义和注释，帮助模型在零样本 NER 任务中保持较高的稳定性 [19]。RT 框架结合信息检索与思维链过程，通过上下文推理进一步提升医学实体的识别准确性 [13]。

上下文学习帮助模型更好地理解实体关系，特别在复杂语义和长距离依赖上优于传统 NER 方法，能够自动提取语义信息，提高准确性和鲁棒性。

2 关系抽取

2.1 关系抽取的概念与发展

关系抽取（RE）是从非结构化文本中识别实体间语义关系并以结构化形式（如三元组）表示的任务。其过程包括关系类型判定和结果结构化表示。早期方法基于卷积神经网络（CNN）和图卷积神经网络（GCN），通过捕捉多层次关系信息提升精度，多粒度特征融合模型通过字符级与词级信息处理多义词，结合外部知识增强语义理解。此外，动态多任务学习方法通过 Attention 机制增强上下文编码灵活性，但计算复杂度较高。基于 RAG 的方法（如 RAG4RE）结合检索、数据增强与生成模块处理多样关系类型，显著提升性能 [14]。在大语言模型出现之前，关系抽取任务面临以下几个困难：（1）对标注数据的高度依赖；（2）长距离依赖和文档级关系的处理能力不足；（3）任务单一且难扩展。

2.2 基于大语言模型的关系抽取

2.2.1 上下文编码

上下文编码通过捕捉文本中实体及其关系的上下文信息，提高关系抽取的准确性。大语言模型的优势在于其强大的上下文感知能力，能够建模复杂语境下的语义关系 [6]。

GPT-RE 方法通过任务感知示例检索和推理逻辑增强上下文学习 [1]。QA4RE 框架将关系抽取转化为多项选择问答任务，结合大语言模型的指令微调提升性能 [23]。召回—检索—推理（RE4）框架结合检索技术与上下文编码，显著提高复杂关系处理能力 [24]。

2.2.2 三元组预测

三元组预测任务直接生成结构化形式（实体 1，关系，实体 2），相较传统流水线方式可减少误差传播。SUMASK 方法通过将三元组预测转化为条件问答，利用大语言模型直接生成答案，在高精度关系抽取中表现优异 [25]。REPLM 框架则通过文档级建模避免命名实体识别误差传播，显著提升文档级关系抽取的表现 [5]。AutoRE 采用任务分解策略并结合 QLoRA 技术，实现高效训练，降低复杂度并提升性能 [10]。

2.2.3 提示学习

提示学习通过设计特定的提示引导大语言模型完成关系抽取任务，特别适用于少样本和零样本场景。与传统方法相比，提示学习能够灵活适应多种任务需求，同时利用大语言模型强大的预训练知识，显著提升抽取性能。

MICRE 通过元训练在上下文中捕捉关系语义，在少样本和零样本任务中提升性能 [9]。

doi:10.3772/j.issn.2095-915x.2025.03.006

CODEIE将信息提取转化为类似编程的任务，利用代码生成模型和提示词设计提升复杂关系预测能力[20]。GoLLIE通过正则化策略增强泛化能力，在零样本和少样本场景中表现出色[21]。

3 实体关系联合抽取

3.1 实体关系联合抽取的概念与发展

实体关系联合抽取是一种自然语言处理任务，是从文本中同时识别出特定实体（如人名、地名、组织等）及其之间的语义关系（如“位于”“属于”“合作”等）。实体关系联合抽取的发展可以分为大语言模型出现之前和之后两个阶段。在大语言模型出现之前，实体关系联合抽取主要依赖于基于规则和统计学习的方法。随着深度学习的兴起，CNN、RNN等模型逐渐被应用于这一任务，尤其是BiLSTM-CRF模型，通过自动学习特征提高了实体识别和关系抽取的精度。大语言模型的出现，如BERT和GPT，标志着实体关系联合抽取技术的革命性进步。

3.2 基于大语言模型的实体关系联合抽取

3.2.1 上下文学习

上下文学习方法通过结合大语言模型的上下文感知能力，将实体和关系的联合抽取任务从单纯的分类问题转化为更灵活的生成或结构化问题。其核心在于利用上下文信息进行语义建模，使模型在标注数据稀缺的情况下依然能够高效完成抽取任务。

自回归文本到图的框架通过Transformer编码器—解码器架构和指向机制，生成线性化图形实现联合实体和关系抽取[16]。上下文学习方法利用知识驱动的提示调优实现zero-shot关系三元组提取，解决了实体和关系标注数据稀缺的问题。InstructUIE通过多任务指令调优适应不同任务，提升了模型的泛化能力和信息抽取效率[25]。RexUIE采用递归模式引导提升了复杂结构下的信息抽取效果[26]。

3.2.2 监督微调

监督微调通过在特定任务或领域的标注数据上进行优化训练，使大语言模型能够适应领域内的复杂实体关系抽取需求。传统方法通常基于固定的模型结构和手工设计特征，这种方式在处理复杂关系或长距离依赖时表现受限。而基于大语言模型的监督微调能够灵活适配不同任务需求，并通过优化整个模型参数显著提升抽取性能。

KPI-BERT结合BERT进行命名实体识别（NER）和关系抽取，显著提高了财务报告中复杂术语和指标的抽取能力。TERS通过引入关系序列信息优化了三元组抽取，并在复杂关系处理中表现突出[12]。CASREL结合BERT编码器和级联二进制标记方法，解决了复杂句子中关系三元组的实体重叠问题[26]。OneRel通过BERT的实体和关系表示学习，实现了高效的一步到位联合抽取[11]。

CodeKGC利用代码语言模型生成知识图谱，提高了信息抽取的准确性和一致性[27]。LoRA微调方法在Transformer架构中嵌入评估模型，有效提升了大语言模型的召回率。UIE集成了监督微调和上下文学习，提升了多任务抽取的语义一致性和高效性[28]。

4 数据集及开源工具

4.1 数据集

在实体关系抽取领域，选择合适的数据集对模型的训练和评估至关重要。下面介绍的是该领域中最常用的几个数据集，它们各具特色，适用于不同的研究需求和任务场景，如表 2 所示。

表 2 公开的关系抽取数据集汇总

数据集	实体类型数	关系类型数	样本数	数据来源	网址
TACRED	10	42	106264	TAC KBP	https://nlp.stanford.edu/projects/tacred/
WebNLG	9	171	18102	DBpedia	https://webnlg-challenge.loria.fr/challenge2017/
FewRel	8	80	56000	维基百科	https://gitcode.com/gh _mirrors/fe/FewRel
NYT	3	24	56196	新闻报道	https://github.com/NYT-Relation-Extraction/nyt-extraction
CoNLL04	4	5	922	国际文本信息检索会议	https://cogcomp.seas.upenn.edu/page/resourceview/43
SciERC	6	7	1861	S2ORC	http://nlp.cs.washington.edu/sciIE/
ACE04	7	7	6202	语言数据联盟	https://catalog.ldc.upenn.edu/LDC2006T09
ACE05	7	6	10051	语言数据联盟	https://catalog.ldc.upenn.edu/LDC2006T06

（1）TACRED 数据集：TACRED 是由斯坦福大学发布的大规模关系抽取数据集。其特色在于标注了多种关系类型，涵盖了广泛的应用场景，TACRED 广泛用于训练和评估关系抽取模型。

（2）WebNLG 数据集：该数据集将从 DBpedia 提取的三元组映射为自然语言文本，适用于关系抽取、文本摘要生成及问答系统等多种自然语言处理任务。

（3）FewRel 数据集：FewRel 是专为少样本关系抽取任务设计的数据集，目标是评估模型在标注样本极少的情况下提取实体间关系的能力。FewRel 的突出特点是其任务设置特别适用于评估大语言模型在低资源环境下的效果。

（4）NYT 数据集：来自《纽约时报》（NYT）的数据集广泛用于关系抽取任务，包含了大量实体和它们之间的关系实例。NYT 数据集的特点是涵盖了多种新闻类型和实体关系，因此适合用于训练模型处理多样化的现实世界数据。

（5）CoNLL04 数据集：CoNLL04 数据集是关系抽取任务中的经典数据集之一，较为简单的任务设置使得它成为初学者和模型基准测试的常用数据集。

（6）SciERC 数据集：SciERC 数据集专注于科学领域，涵盖了超过 10000 篇科学论文，标注了 5 种主要关系类型，特别适合用于复杂学术领域的关系抽取研究。它为研究人员提供了一个在专业领域中进行关系抽取的良好平台，特别适合处理学术文献中长句和领域特有术语带来的挑战。

（7）ACE 系列数据集由语言数据联盟（LDC）提供，包含了新闻专线和广播新闻文档，主要用于实体识别、指代消解和关系抽取任务。ACE 数据集的优势在于其权威性和多任务设置，能够广泛用于信息抽取领域的评测，特别是在新闻领域中应用广泛。

doi:10.3772/j.issn.2095-915x.2025.03.006

4.2 开源工具

开源工具在实体关系抽取领域广泛使用，因为它们提供了丰富的模型支持、高效的开发流程和灵活的接口，满足了研究和实际应用的需求，其基本情况如表 3 所示。以下是常用工具的特点：

（1）Hugging Face Transformers 提供多种预训练模型（如 LLaMA、GPT-2、RoBERTa），便于快速 fine-tuning 和应用，支持文本分类、问答、关系抽取等多种任务，灵活高效，是学术界和工业界的首选。

（2）OpenAI API 支持 GPT-3 和 GPT-4 等大语言模型，具备卓越的上下文理解和生成能力，适合复杂任务，如实体关系抽取和多跳推理，能在少样本甚至零样本的条件下完成高质量的预测。

（3）AllenNLP 是基于 PyTorch 的开源自然语言处理库，支持主流 NLP 架构，包括 BERT、RoBERTa 和 ELMo，广泛用于阅读理解、关系抽取等任务。

（4）spaCy 是一个开源的自然语言处理库，提供高效的 Transformer 模型支持，特点在于其高效的推理速度和简单的 API 设计，适合大规模关系抽取任务，广泛应用于工业领域。

5 测评标准及实验

在命名实体识别（NER）和实体关系抽取任务中，常用的评测指标包括精确率（Precision）、召回率（Recall）和 F1 值（F1-Score），分别衡量模型的预测准确性、覆盖率以及两者之间的平衡。这些指标能够反映模型在捕捉实体、理解上下文以及预测关系上的能力，同时为不同模型之间的性能比较提供了标准化的依据。

从表 4 可以看到，使用大语言模型的命名实体识别在多个数据集上表现出更优异的性能，这表明大语言模型在捕捉上下文信息和处理复杂语言结构方面具有显著优势，尤其是处理多样化和具有复杂关系的任务。

表 3 不同开源工具的 Backbone 模型以及 ICL 和 COT 的使用情况

工具 / 库	使用的 Backbone 模型	是否使用 ICL	是否使用 COT
Hugging Face Transformers	BERT、GPT、T5 等	支持（根据模型）	支持（根据模型）
OpenAI API	GPT-4、GPT-3、Codex 等	是	是
AllenNLP	BERT、RoBERTa、ELMo、GPT-2 等	否	否
spaCy	Transformer（BERT、RoBERTa 等）	否	否

表 4 命名实体识别 SOTA 方法在 CONLL04 和 ACE04 数据集性能对比

数据集	模型	P	R	F
CoNLL04	Yan[7]	92.61	93.87	93.24
	Chen[22]	73.59	57.19	64.34
	Yan[15]	92.86	90.98	91.91
	Ding[17]	90.62	92.07	91.34
	Sainz[21]	—	—	93.10
	Lu[29]	—	—	92.52
ACE04	Li[30]	85.05	86.32	85.98
	Yuan[31]	88.88	88.24	88.56
	Sainz[21]	—	—	89.60

从表 5 中可以看出，监督微调技术通常在关系提取任务中表现优于上下文学习技术，尤其是在 NY 和 CoNLL04 数据集上，其中 BERT-large 和 Flan-T5-11B 模型的表现尤为突出。数据集的不同特性显著影响模型性能，例如 ACE05 和 SciERC 数据集对模型的挑战较大。整体而言，大型预训练模型的监督微调方法在多个数据集上的综合表现优于上下文学习方法。随着模型规模的增加，实体关系联合抽取的 F1 值普遍有所提升。

表 5　实体关系联合抽取 SOTA 方法在五个数据集性能对比表

			数据集				
技术	模型	backbone	NYT	ACE05	ADE	C0NLL04	SciERC
上下文学习	Li[20]	Code-davinci-002	32.17	14.02	—	53.1	7.74
	Bi[27]	Text-davinci-003	—	—	64.6	49.8	24.0
	Guo[32]	Text-davinci-002	54.4	17.5	58.6	54.4	—
监督微调	Lu[29]	T5-large	—	66.06	—	75.0	36.53
	Wang[25]	Flan-T5-11B	90.47	—	82.31	78.48	45.15
	Sainz[21]	Code-LLaMA-34B	—	70.1	—	—	—
	Lou[28]	RoBERTa-large	—	67.88	—	78.84	37.36
	Liu[8]	DeBERTa-v3-large	—	64.87	—	78.39	38.37

6　未来工作

6.1　长文本与跨句关系建模方法

基于 LLMs 的文档级关系抽取（DocRE）未来有望在跨句子推理和长距离依赖关系处理方面取得突破。通过结合少样本学习和自适应学习，模型在多领域和多语言环境中的泛化能力将进一步增强。此外，未来研究将更加关注模型的可解释性，开发显式推理链和多跳推理模型，使关系提取过程透明化。随着多模态数据的普及，DocRE 系统可能融合文本、图像等数据源，构建全面的文档表示，从而进一步提高关系提取的准确性。

6.2　实体关系抽取的数据增强

未来，自动化数据生成将成为数据增强的重要手段。基于 LLMs 的生成模型能够扩展数据集，生成多样化的正样本、负样本以及罕见关系样本，提升模型对长尾关系的处理能力。此外，跨领域和跨语言的数据增强技术将利用 LLMs 的迁移能力，解决数据稀缺问题，并提升模型在多语言、多领域应用中的表现。随着多模态技术的发展，结合图像、音频等数据源的跨模态数据增强方法将生成更丰富的训练数据，从而提升模型对复杂上下文和关系的理解能力。

7　总结

本文系统地总结了基于大语言模型的实体关系抽取技术，主要从命名实体识别、关系抽取和实体关系联合抽取 3 个方面展开讨论。首先回顾了传统实体关系抽取方法的局限性，强

doi:10.3772/j.issn.2095-915x.2025.03.006

调了大语言模型在处理少样本和零样本任务中的优势。随后，详细介绍了当前基于大语言模型的方法在各类任务中的表现，分析了这些模型在公开数据集上的实验结果，并探讨了不同方法的性能差异。综述还梳理了常用的公开数据集和评价指标，总结了现有技术的不足，如对大规模数据的处理能力、上下文理解和抽取效率方面的挑战。最后，文章提出了未来的研究方向，为研究者提供了清晰的研究路径和发展思路。

参 考 文 献

[1] 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.

[2] SMIRNOVA A, CUDRÉ-MAUROUX P. Relation extraction using distant supervision: A survey[J]. ACM Computing Surveys (CSUR), 2018, 51(5): 1-35.

[3] NASAR Z, JAFFRY S W, MALIK M K. Named entity recognition and relation extraction:State-ofthe-art[J]. ACM Computing Surveys (CSUR), 2021, 54(1): 1-39.

[4] YE J, XU N, WANG Y, et al. Llm-da: data augmentation via large language models for few-shot named entity recognition[J]. arXiv preprint arXiv: 2402. 14568, 2024.

[5] OZYURT Y, FEUERRIEGEL S, ZHANG C. Incontext few-shot relation extraction via pre-trained language models[J]. arXiv preprint arXiv: 2310. 11085, 2023.

[6] TANG X, WANG J, SU Q. Small language model is a good guide for large language model in chinese entity relation extraction[J]. arXiv preprint arXiv: 2402. 14373, 2024.

[7] YAN H, GUI T, DAI J, et al. A unified generative framework for various NER subtasks[C]// Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. 2021: 5808-5822.

[8] LIU C, ZHAO F, KANG Y, et al. RexUIE: a recursive method with explicit schema instructor for universal information extraction[C]// Findings of the Association for Computational Linguistics: EMNLP 2023. 2023: 15342-15359.

[9] LI G, WANG P, LIU J, et al. Meta in-context learning makes large language models better zero and fewshot relation extractors[J]. arXiv preprint arXiv: 2404. 17807, 2024.

[10] XUE L, ZHANG D, DONG Y, et al. AutoRE: document-level relation extraction with large language models[C]// Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics. 2024: 211-220.

[11] YAN Z, YANG S, LIU W, et al. Joint entity and relation extraction with span pruning and hypergraph neural networks[C]// Proceedings of the 2023 Conference on Empirical Methods in Natural Language Processing. 2023: 7512-7526.

[12] ZHANG Z, ZHANG H, WAN Q, et al. Entityrelation triple extraction based on relation sequence information[J]. Expert Systems with Applications, 2024(238): 121561.

[13] LI M, ZHOU H, YANG H, et al. RT: a retrieving and chain-of-thought framework for few-shot medical named entity recognition[J]. Journal of the American Medical Informatics Association, 2024: ocae095.

[14] EFEOGLU S, PASCHKE A. Retrieval- augmented generation-based relation extraction [J]. arXiv preprint arXiv: 2404. 13397, 2024.

[15] YAN F, YU P, CHEN X. LTNER: large language model tagging for named entity recognition with contextualized entity marking[C]// International Conference on Pattern Recognition. Springer, Cham, 2025: 399-411.

[16] ZARATIANA U, TOMEH N, HOLAT P, et al. An Autoregressive Text-to-Graph Framework for Joint

Entity and Relation Extraction[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2024, 38(17): 19477-19487.

[17] DING N, XU G, CHEN Y, et al. Few-NERD: a fewshot named entity recognition dataset[C]// Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. 2021: 3198-3213.

[18] ZHOU R, LI X, HE R, et al. MELM: data augmentation with masked entity language modeling for low-resource NER[C]// Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics. 2022: 2251-2262.

[19] ANDREW Z, ANDREA Z, LEONARDO R, et al. Show less, instruct more: Enriching prompts with definitions and guidelines for zero-shot ner[J]. arXiv preprint arXiv: 2407. 01272, 2024.

[20] LI P, SUN T, TANG Q, et al. CodeIE: large code generation models are better few-shot information extractors[C]// Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics. 2023: 15339-15353.

[21] SAINZ O, GARCÍA-FERRERO I, AGERRI R, et al. GoLLIE: Annotation guidelines improve zero-shot information-extraction[C]// The Twelfth International Conference on Learning Representations. 2023.

[22] CHEN J, LU Y, LIN H, et al. Learning in-context learning for named entity recognition[C]// Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics. 2023: 13661-13675.

[23] ZHANG K, GUTIÉRREZ B J, SU Y. Aligning instruction tasks unlocks large language models as zero-shot relation extractors[C]// Findings of the Association for Computational Linguistics: ACL 2023. 2023: 794-812.

[24] LI G, WANG P, KE W, et al. Recall, retrieve and reason: towards better in-context relation extraction[J]. arXiv preprint arXiv: 2404. 17809, 2024.

[25] WANG X, ZHOU W, ZU C, et al. Instructuie: Multitask instruction tuning for unified information extraction[J]. arXiv preprint arXiv: 2304. 08085, 2023.

[26] WEI Z, SU J, WANG Y, et al. A novel cascade binary tagging framework for relational triple extraction[C]// Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. 2020: 1476-1488.

[27] BI Z, CHEN J, JIANG Y, et al. Codekgc: code language model for generative knowledge graph construction[J]. ACM Transactions on Asian and Low-Resource Language Information Processing, 2024, 23(3): 1-16.

[28] LOU J, LU Y, DAI D, et al. Universal information extraction as unified semantic matching[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2023, 37(11): 13318- 13326.

[29] LU J, YANG Z, WANG Y, et al. PaDeLLM-NER: parallel decoding in large language models for named entity recognition[J]. arXiv preprint arXiv: 2402. 04838, 2024.

[30] LI X, FENG J, MENG Y, et al. A unified MRC framework for named entity recognition[C]// Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. 2020: 5849-5859.

[31] YUAN Z, TAN C, HUANG S, et al. Fusing heterogeneous factors with triaffine mechanism for nested named entity recognition[C]// Findings of the Association for Computational Linguistics: ACL 2022. 2022: 3174-3186.

[32] GUO Y, LI Z, JIN X, et al. Retrieval- augmented code generation for universal information extraction[C]// CCF International Conference on Natural Language Processing and Chinese Computing. Singapore: Springer Nature Singapore, 2024: 30-42.