

面向安全环保领域的知识图谱增强大模型探讨

明平寿¹ 杨恒^{1*} 兰弄² 文志强² 皮理想¹ 周本胜¹ 袁怀月¹

1 中冶武勘工程技术有限公司 2 广西柳州钢铁集团有限公司

DOI:10.12238/acair.v3i1.11916

[摘要] 为解决钢铁企业安环领域数智化实施过程中存在的信息透明度不足、传递不及时、数据难以分析以及分析结果难以被业务人员理解等问题,引入能深度理解和应用安全和环保领域内的专业知识,提供准确和专业的信息,为复杂问题提供专业回答和解决方案大语言模型。然而,大模型自身面临解释性不足、知识实时性差、生成结果存在虚假信息等诸多挑战。知识图谱作为一种结构化的知识模型,其真实性和可靠性,成为提高大模型解释和推理能力的有力工具。因此结合二者的优势,本文探讨知识图谱增强大模型几个方向,为安环领域的数智发展提供参考。

[关键词] 钢铁企业; 安环领域; 数智化; 大语言模型; 知识图谱

中图分类号: TP9 文献标识码: A

Exploring Directions for Knowledge Graph-Enhanced Large Models in the Safety and Environmental Protection Sector

Pingshou Ming¹ Heng Yang^{1*} Nong Lan² Zhiqiang Wen² Lixiang Pi¹ Bensheng Zhou¹ Huaiyue Yuan¹

1 WSGRI Engineering & Surveying Incorporation Limited 2 Liuzhou Iron and Steel Co., Ltd

[Abstract] To address the challenges of digital implementation in the safety and environmental protection (EHS) sector within steel companies, including lack of information transparency, delayed transmission, difficulties in data analysis, and the complexities faced by business personnel in understanding analytical results, this paper introduces large language models equipped with deep understanding and application capabilities in safety and environmental knowledge. These models provide accurate and professional information and propose solutions to complex problems. However, large models face several issues such as insufficient explainability, poor timeliness of knowledge, and the generation of false information. Knowledge graphs, as structured knowledge models, offer authenticity and reliability, thereby enhancing the explanatory and inferential capabilities of large models. By leveraging the strengths of both, this paper discusses various approaches for enhancing large models with knowledge graphs, providing insights for the digital advancement in the EHS sector.

[Key words] Steel Industry; Safety and Environmental Sector; Digitalization; Large Language Models; Knowledge Graphs

引言

钢铁行业作为全球经济的基石,承担着支撑基础设施建设、交通运输、制造业等多个领域的重要职责。根据国际钢铁协会的数据显示,2022年全球粗钢产量达到18.7亿吨,其中中国占据了超过一半的份额。这一庞大的市场规模不仅反映了钢铁行业在国民经济中的重要地位,也突显了其在应对环境挑战和实现可持续发展方面的责任。近年来,随着全球经济的快速发展与产业结构的不断调整,钢铁行业面临着日益严峻的挑战。一方面,传统的高能耗、高排放生产模式已难以适应日益严格的环保政策和市场对绿色产品的需求。另一方面,国际市场竞争的加剧以及原材料价格的波动,使得行业的盈利能力受到严重影响。技术

创新是推动钢铁行业可持续发展的重要驱动力。

近年来,智能制造、大数据和物联网等新技术的应用逐渐成为行业转型的重点。此外,绿色生产技术的发展,如低碳冶炼和废钢回收利用,正在重塑钢铁生产的生态环境。同时,政策环境的变化也对行业发展产生了深远影响,各国政府纷纷出台相关政策,推动行业向环保和低碳转型。因此,应重视安全环保行业的发展。近年来,大模型的涌现能力在各个垂直领域取得了一定的进展,聚焦安全环保垂直领域的大模型构建,整合安全环保行业知识,使模型能够深度理解和应用安全和环保领域内的专业知识,提供准确和专业的信息,为复杂问题提供专业回答和解决方案是钢铁安环领域数智发展的重要方向。然而大模型仍然面

面临着诸多挑战,包括模型内部的不可控性,缺乏解释性、无法保证知识实时性、语言数据质量的不确定性,以及产生幻觉和有毒信息的潜在风险。知识图谱以其数据的真实性而著称,这一特点可以有效地减轻大模型产生幻觉的问题。知识图谱使用图结构表示知识,其中节点表示实体,边表示实体之间的关系。自2012年谷歌推出知识图谱以来,知识图谱在知识表示中变得至关重要,很多公司使用它们来提高产品性能,提高推荐系统的数据表示和透明度,提高问答系统的效率,以及信息检索系统的准确性。因此本文探讨知识图谱增强大模型的几个方向,为安环领域提供管理决策参考。

1 大模型相关介绍

大模型是指具有超大规模参数量和数据量的神经网络模型。大模型通过从大量文本或多模态数据中学习语言和模式识别能力,可以更好地理解和处理自然语言,甚至生成新的文本或内容。近年来,随着模型不断发展,人机交互与智能化的前景正随之快速变化。大模型的原理是基于深度学习,利用大量的数据和计算资源来训练具有大量参数的神经网络模型。通过不断的调整模型参数,使得模型能够在各种任务中取得最佳表现。其特点在于参数量庞大、训练数据量大、计算资源需求高等,在许多科学和工程领域引起了具有颠覆性与变革性的全新研究范式。目前,OPENAI的聊天机器人ChatGPT的推出让问答领域的研究变得更加火热,并且随着语言模型的迭代,人工智能的智力水平已经越来越逼近真正的人类。

在大模型的能力方面的研究,Yang等人以具有代表性的大型语言模型ChatGPT,探索了语境学习在基于实体的多模态情绪分析任务中的潜力,开发了一个带有任务指令的通用ICL框架用于零样本学习,通过在提示符中引入少量的示范样本将其扩展到少样本学习,并通过实验验证了采用微调大模型在MEBSA子任务上表现出优异的性能;Sun等人提出了一种名为“Clue And Reasoning Prompting”的渐进式推理策略框架,用以缓解GPT系列大型语言模型处理复杂语言现象时缺乏推理能力和token数量限制问题;Liu等人针对直接使用现成的描述模型为LLMs的示例提示,从而导致LLMs给出错误的预测的问题,提出了一种带有LLM反馈的零样本学习VQA(ZVQAF),该框架应用LLM来区分生成的字幕的质量,并利用这个反馈来训练字幕模型。通过带反馈的训练,使提示模型能够从LLM中识别任务目标和信息需求,利用优化的描述模型和LLM进行推理,使得大模型在ZVQAF上基于零样本学习实现准确的问题预测;Reshma等人将深度学习模型与大语言模型在自然语言处理领域的应用情况作对比,将使用预训练语言模型和提示工程方式处理问题效果与采用深度学习经过大规模训练得到的结果相比,发现大模型在小样本微调的情况下处理自然语言问题依然具有较好的处理效果^[1]。

在大模型的应用方面,Mohamed等人结合大模型,采用基于规则的方法和混合方法从电子医疗文件中提取信息,且验证了这种方法为信息抽取有前途的技术;Webson等人验证了在大语言模型prompt和案例学习对复杂文本信息抽取的作用;Wu等人

提出一种基于生物医学文献的预训练语言模型,通过对LLaMA模型进行微调,注入医疗知识以增强其在医疗领域专业的能力,从而提高其在医疗问答基准测试中的表现;SINGHAL等人在医疗领域,提出MultiMedQA医学问题回答基准,涵盖了医学考试、医学研究和消费者医学问题;Yun等人使用医疗领域知识对LLaMA模型进行微调获取医疗聊天模型,其根据在线医疗咨询网站的10万条真实世界患者医生对话,对模型进行了微调,添加了自主知识检索功能,通过构建适当的提示在大语言模型中实现具体检索功能。

2 知识图谱相关介绍

知识图谱是一种用于表示和存储结构化知识的图形知识库,以实体和实体之间的关系构成的三元组(头实体,关系,尾实体)为基本组成单位。垂直领域知识图谱,专业知识的联系更为繁杂,在知识的表示上难度更大,而且对于知识的准确性要求更高。就要求在知识的来源、处理、本体定义等流程上都达到高质量的标准,才有进一步使用的价值和意义。垂直知识图谱的构建是将大量结构化、半结构化或非结构化的数据通过知识抽取、知识融合、知识推理等操作之后加入知识库,初步构建后,再进行不断地增量迭代来丰富所构建的知识图谱。

针对知识表示,Qin等针对大规模个性化产品,考虑制造资源相互作用、制造环境的动态特性及自适应制造控制等因素,提出了基于知识图谱的动态制造环境下自适应制造控制语义表示方法。Gajewski等提出一种基于对象特征和可用性的任务表示方法,提高了任务知识的泛化和可解释性^[2]。针对知识抽取,Zhong等提出的PURE方法利用先抽取出的实体结果,并加上实体类型标签做提示,设计了悬浮标记的方法,完成关系抽取任务^[3]。Nan等提出了一种基于潜在结构化文档级关系推理方法^[4]。针对知识融合,郭浩等针对多模态知识图谱中存在的知识不完整问题,提出依据不同模态数据质量动态融合实体结构信息和视觉信息的自适应特征融合方法。Shen等人针对图谱的结构稀疏性和噪声路径问题,提出了一种属性体现的神经关系路径预测模型来预测图谱中实体之间的缺失关系^[5],帮助从噪声路径中学习更有价值的信息以进行关系预测;He等人针对知识图谱不完备的问题,提出了面向知识图谱的增强型知识图谱嵌入框架,进一步提升了图谱补全的性能。

随着对大数据处理的需求不断增长,知识图谱补全的重要性也日益凸显。传统的知识补全模型主要包括基于翻译的模型和基于张量分解的模型。Li等提出基于高效关系旋转的知识图谱补全方法,这是基于翻译的知识图谱补全模型的简单而有效的替代方法^[6]。Nickel等提出的RESCAL模型是最具代表性的张量分解模型之一^[7]。Yu等提出基于关系交互的块项分解知识图谱补全模型,该模型利用逆关系的强化增强正向关系和逆向关系的融合^[8]。为了适应复杂的知识图谱补全任务,翻译模型需要具备较强的语义建模能力和泛化能力,并且需要足够的标注数据来训练模型。同时,面对数据稀疏性和长尾实体、关系的情况时,可能会出现泛化能力不足的问题。由于张量分解模型忽略了

实体和关系之间的上下文信息,对于长尾实体和关系的建模效果不够理想,且嵌入表示方式较为简单,无法表达实体和关系的更多信息。

基于神经网络的知识图谱补全模型具有端到端学习、多层次表示学习、结合语义信息和多任务学习等特点,是目前研究热点之一。基于卷积神经网络的知识补全模型可以通过卷积操作捕捉实体和关系之间的语义信息,并将其映射到低维空间中;基于图神经网络的知识补全模型可以通过学习实体和关系的图结构,对实体和关系进行表示;基于胶囊网络的知识补全模型则可以利用胶囊层对实体和关系进行表示,保留实体和关系之间的方向性信息,实现链接预测。邹龙等提出基于邻域聚合与卷积神经网络的知识图谱实体类型补全模型。Zhai等提出了一种新的多模态知识图谱补全方法,旨在学习多层次的图结构特征,以充分挖掘知识图谱中隐藏的关系,提高推理精度。

元学习的一个重要目标就是使得机器学习模型能够从少量或者甚至零个样本中快速地适应新任务或者新领域。元学习的方法被广泛应用于少样本知识补全和零样本知识补全领域,能够快速适应新的实体和关系,预测未知实体之间的关联,提高预测的准确性和泛化能力。Li等提出用于少样本知识图谱补全框架,通过对三元组的图上下文建模学习每个少量关系的全局和局部特定关系表示,以提供比直接邻域更丰富的关系依赖,同时又不会丢失有价值的实体局部信息。大部分知识图谱补全方法的性能高度依赖于已知知识图谱的质量,零样本学习是用来预测没有标记训练数据的看不见的类,能够应对知识图谱补全的冷启动场景。为了预测知识图谱中看不见的知识,Qin等提出零样本补全模型ZSGAN。

3 知识图谱增强大模型

大模型自身面临解释性不足、知识实时性差、生成结果存在虚假信息等诸多挑战。知识图谱作为一种结构化的知识模型,其真实性和可靠性,成为提高大模型解释和推理能力的有力工具。尽管大模型在处理自然语言下游任务时,表现出色的性能,但是大模型仍存在一些致命缺陷问题尚未解决,例如大模型理解问题需要依赖上下文信息,逻辑推理能力不足、输出存在幻觉和编造的现象。这些问题导致大模型输出结果存在虚假性,可能对社会和道德产生负面影响。

3.1 增强大模型自身性能

大模型幻觉的缺陷是语言模型的通病,主要在于生成文本时过度依赖语言模型的概率分布,并且大模型自身不考虑文本是否与现实世界或常识一致,以及预训练数据可能包含错误、过时、有偏见或有争议的信息。研究表明,使用结构化的数据可以提高大模型的性能,有助于大模型确认事实性问题,从模型本身的角度避免幻觉与编造。因此在大模型预训练阶段,可将知识图谱中的结构化信息(实体、关系、链接路径)作为训练数据,增强大模型自身涌现能力。

事实上,在BERT和GPT为代表的预训练模型发布不久,不少学者已经开始研究知识增强型预训练模型。例如将知识图

谱的三元组作为领域知识注入到句子^[9,10],以及实体链接模型KnowBERT。如今知识内嵌大模型通常是采用对齐技术将知识图谱与自然语言相关联。例如ERNIE和ERNIE 3.0。ERNIE是一种增强语言表示模型,通过构造结构化知识编码模块,将知识纳入语言理解,显著提高知识驱动的性能。ERNIE 3.0则是对其进行改进,同时融合自回归网络和自编码网络,使用大量纯文本和大规模知识图谱进行训练。不同于上述模型,SKILL设计一种直接在知识图谱的事实三元组上训练T5模型的方法,避免了知识图模型之间的差异,使模型能够轻易学习内嵌的事实化知识,应用在各种行业领域的问答工作中。此外,知识增强型大模型还包括集成实体间的细粒度关系的预训练语言模型KLMo、统一知识嵌入和预训练语言表示模型KEPLER、将知识图数据转换为自然语言的嵌入模型以及基于ChatGPT的黑箱知识注入方法KnowGPT。

3.2 增强大模型自身性能

大模型在处理结构化推理方面(如解决数学问题)表现不佳,目前增强大模型推理能力的技术主要有思维链(CoT)、思维树(ToT)、思维图GoT)等等。思维链是一种通过少样本示例提示来增强大型模型推理任务的方法,它能够通过生成中间推理步骤执行复杂的推理。然而,思维链模型在使用偏见特征时可能会导致推理结果受到影响,改变其原本的方向。通常情况下,大模型被视为黑箱模型,即使是开源模型也很难显式判断其内部推理链和决策过程,为了克服大型模型在结构化推理方面的不足,可将知识图谱结构化推理、支持可解释的预测的能力与大型模型结合起来。JointLK和QA-GNN则采用图神经网络(GNN)和知识图谱来提高模型推理能力。相较于以往文本与知识独立的模式,QA-GNN将问题上下文与检索到的知识连接起来,构成一个联合图^[11-13]。实验表明,相比较于RoBERTa,QA-GNN表现出更好的效果。JointLK模型则是在QA-GNN模型上的优化,由于QAGNN仅将QA上下文作为一个额外节点附加到知识图,无法完成双向交互。而JointLK通过密集的双向注意力模块实现语言模型和知识图谱的多步联合推理。具体来说,JointLK模型将任务文本信息与外部知识图谱数据这两种不同模态的信息结合起来,设计了一个联合推理模块,在每个问题标记和每个知识图谱节点之间生成细粒度的双向注意映射,实现不同模态信息的融合。同时,JointLK模型设计了一个动态图裁剪模块,通过移除无关的图节点进行去噪,以确保模型正确地使用完整和适当的证据进行推理。实验结果表明,JointLK在解决带有否定词的复杂推理问题方面表现出色。DRAGON模型在文本和知识图的深度双向联合(QA-GNN)的基础上,采用自监督学习策略。通过统一两个自我监督的推理任务,包括掩码语言建模和链接预测,DRAGON模型实现了对文本和知识图的全面预训练。这种自监督学习策略使得模型能够更好地理解文本和知识图之间的关系,从而更准确地进行推理。

3.3 增强大模型检索

知识图谱通过检索增强大模型是自然语言处理领域备受关注的研究方向之一。一种代表性的方法是检索增强生成。大模

型自身无法精确处理知识密集型任务,也无法探究信息的来源和知识的更新,RAG旨在通过外部真实知识向量索引来解决大模型无法自我更新知识的问题^[14]。RAG是一种包含查询编码器、预训练检索器和预训练的生成式模型相结合的端到端训练方法。具体步骤为通过文档检索器检索潜在信息,将潜在文本作为输入信息的附加上下文执行大模型,最终获得文本目标序列与之类似,LaMDA模型包括LaMDA-Base和LaMDA-Research模型,在执行过程中,首先调用LaMDA-Base模型生成输出,但是输出结果可能存在不真实信息,模型会继续调用LaMDA-Research与信息检索系统进行多次交互,直到LaMDA-Research响应用户输出,将无法验证的结果进行替换。相较于RAG,LaMDA的检索范围较小,但检索结果的精确度相对较高。为了解决大模型内存开销过大的问题,RETRO通过从大型语料库中检索相似文档块来增强语言模型,在处理下游知识密集任务时,小参数模型性能达到了GPT-3的表现效果。RAG和RETR二者都需单独训练检索模型,并且在面对超大规模和更新性强的外部文档时,可能会导致计算成本的增加。在检索的基础上,KaLMA构建了一个基于检索、重新排序和生成的管道,检索增强大模型的知识感知属性,同时提出“Conscious Incompetence”的设置,即当语言模型意识到自己无法提供某些知识,会在文本中插入“[NA]”标记,表示该部分知识无法被验证。实验结果表明,KaLMA在提高大模型的引用生成能力和检索准确性方面具有一定的潜力。与上述不同,KMLM是一种直接基于多语言三元组的知识增强型预训练方法,将三元组信息以代码形式转化为多语言文本,同时在预训练过程中附加文本的结构信息,实验结果表明,KMLM提高了隐性知识的推理能力,跨语言知识密集型任务(事实知识检索)中表现出显著的性能改进。

3.4 增强大模型可解释性

大模型因其异常复杂的结构、庞大的参数量、对大规模文本数据的高依赖性等问题,往往很难提供具备逻辑推理过程的解释,在许多领域(如生物医疗、军事和金融等)是无法接受的。并且大模型内部工作机制难以理解,加之模型输出的不确定性,导致相同输入可能得到不同输出,即使目前性能比较出色的大模型GPT-4也存在不可解释性的问题。传统解决模型可解释性问题的方法集中于模型内在和事后的解释,如可解释模型结构和事后特征选择。然而,这些方法在解释模型决策过程方面存在不足。近期研究通过多实例学习、注意矩阵和外部知识结构等手段提供文本解释,但仍未完全理解模型的推理过程。LMExplainer设计了一个知识增强的解释模块,将知识图谱与大模型相结合,采用知识图谱和图注意力网络(GAT)提取大模型的关键决策信号,提供了全面、清晰、可理解的文本解释^[15,16]。通过大模型生成输入语言的嵌入,同时从知识图谱中检索到相关知识以构建子图,以语言嵌入和子图作为图神经网络的输入,通过图注意力网络来获取注意力分数,生成最终的预测结果和决策的解释过程。实验结果显示,LMExplainer不仅提高了模型性能,并且可以更准确地解释模型推理过程。同样的,XplainLLM

是首个捕捉大模型推理元素并通过人类可理解的解释呈现决策过程的数据集,满足大模型在决策过程中透明度、可解释性和可理解性的需求。通过结合知识图和图注意力网络,构建一个问题-答案-解释(QAE)三元组,将大模型推理过程与知识图谱中实体和关系相连接的。评估结果显示,使用解释后的大模型性能提高2.4%,并且在问答任务中具有更出色的可解释性和理解效果。

4 结束语

本文探讨了安环领域知识图谱增强大模型的四个方向:增强大模型自身性能、增强大模型推理、增强大模型检索、增强大模型可解释性。知识图谱与大模型各有优势,各有不足,未来可以考虑图模互补,构建知识图谱和大模型协同的系统,建立有效的反馈机制以动态调整和优化知识图谱与大模型之间的互动。在工业实践中,需要整合知识图谱和大语言模型。一方面,利用大语言模型的文本理解能力,自动处理大量本地非结构化文档,在零样本或者少样本前提下,进行实体识别和关系抽取的工作,构建知识图谱的节点和边,并消除可能存在的重复或歧义;另一方面,基于知识图谱的检索增强生成模型,让大语言模型具备查询、推理本地知识能力,解决通用基座模型仅能解决通用任务,无法直接服务于特定行业和企业、回答内容存在“幻觉”的问题。

[参考文献]

- [1]Zhaojun Q,Yuqian L.A Knowledge Graph-based knowledge representation for adaptive manufacturing control under mass personalization[J].Manufacturing Letters,2023,35(S):96-104.
- [2]Gajewski,Indurkha.An Approach to Task Representation Based on Object Features and Affordances[J].SENSORS,2022,22(16):615.
- [3]Zhong Z,Chen D.A Frustratingly Easy Approach for Joint Entity and Relation Extraction[J].2020.
- [4]Nan G,Guo Z,Sekulici, et al. Reasoning with latent structure refinement for document-level relation extraction[J].arXiv:2005.06312,2020.
- [5]Peng H,Gang Z,Yao Y, et al. A type-augmented knowledge graph embedding framework for knowledge graph completion [J].Scientific reports,2023,13(1):12364-12364.
- [6]Li J,Su X. Transerr: translation-based knowledge graph completion via efficient relation rotation[J].arXiv:2306.14580, 2023.
- [7]Nickel M, Tresp V, Kriegel H P. A three-way model for collective learning on multi-relational data[C]//Proceedings of the International Conference on Machine Learning, c2011: 809-816.
- [8]Yu M, Guo J, Yu J, et al. BDRI: block decomposition based on relational interaction for knowledge graph completion[J]. Data Mining and Knowledge Discovery,2023,37(2):767-787.

[9]Sui Y,He Y, Liu N, et al. FiDeLiS: Faithful Reasoning in Large Language Model for Knowledge Graph Question Answering [J].arxiv preprint arxiv:2405.13873,2024.

[10]Guo T, Yang Q, Wang C, et al. Knowledge navigator: Leveraging large language models for enhanced reasoning over knowledge graph[J].Complex & Intelligent Systems,2024:1-14.

[11]YAO S Y,YU D,ZHAO J,et al.Tree of thoughts: Deliberate problem solving with large language models[J]. Advances in Neural Information Processing Systems,2024,36:11809-11822.

[12]BESTA M, BLACH N, KUBICEK A, et al. Graph of thoughts: Solving elaborate problems with large language models[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2024,38(16):17682-17690.

[13]GUAN Z H,WU Z H, LIU Z L, et al. CohortGPT: An enhanced GPT for participant recruitment in clinical study [EB/OL]. 2023:arXiv:2307.11346.http://arxiv.org/abs/2307.11346.

[14]TURPIN M, MICHAEL J, PEREZ E, et al. Language models

don't always say what they think: Unfaithful explanations in chain-of-thought prompting[EB/OL]. 2023: arXiv: 2305.04388. <http://arxiv.org/abs/2305.04388>.

[15]SUN Y Q, SHI Q, QI L, et al. JointLK: Joint reasoning with language models and knowledge graphs for common-sense question answering[EB/OL].2021:arXiv:2112.02732.

[16]YASUNAGA M,REN H Y,BOSSELUT A,et al.QAGNN: Reasoning with language models and knowledge graphs for question answering[EB/OL].2021:arXiv:2104.06378.<http://arxiv.org/abs/2104.06378>.

作者简介:

明平寿(1993--),男,汉族,湖北省黄石市人,硕士,工程师。研究方向为数字智慧应用。

*通讯作者:

杨恒(1980--),男,汉族,湖北省襄阳市人,硕士,高级工程师。研究方向为数字智慧应用。