

融合深度学习与知识图谱的导航迷路场景理解方法

陈虎, 杨林, 左泽均, 罗明霞

(中国地质大学(武汉)计算机学院, 湖北武汉 430072)

摘要: 导航是人们日常生活中不可或缺的一部分, 在导航过程中迷路是一个常见问题。为此, 利用出行活动反馈的导航文本数据构建一个导航迷路知识图谱(NLKG), 以理解导航迷路场景。首先, 为了实现NLKG的可用规模, 收集了来自微博平台2万余条迷路相关文本, 构建了一个人工标注语料库, 涵盖1万多个高质量实体标注和4 000余条关系标注, 并在此基础上依据地形、道路和街道环境等多维信息, 定义了25类实体和20种关系类型, 建立了NLKG的概念模式, 实现了规模化、结构化的知识表达。其次, 提出一个面向导航迷路文本的三元组联合抽取模型NavLTR, 全面捕捉序列数据中的长距离依赖关系, 充分建模导航实体间的复杂关系, 自动抽取与迷路经验相关的实体和关系, 以构建可用的NLKG实例。最后, 基于NLKG进行迷路因素重要度分析、典型迷路场景因素分析、迷路风险预测、迷路因素关联性分析和智能问答Agent系统构建, 展示其应用前景和价值。实验表明, 所提方法能有效缓解NLKG稀缺性问题, 为整合多源多模态数据优化导航经验认知提供了示范, 对优化导航决策和改善导航体验具有重要意义。

关键词: 导航迷路; 知识图谱; 导航决策; 时空信息抽取; 多源知识整合

DOI: 10.11907/rjtk.251414

扫描二维码阅读全文:



中图分类号: TP391

文献标识码: A

文章编号: 1672-7800(2026)008-0060-12

Navigational Lost Scene Understanding Method Integrating Deep Learning and Knowledge Graph

CHEN Hu, YANG Lin, ZUO Zejun, LUO Mingxia

(School of Computer Science, China University of Geosciences (Wuhan), Wuhan 430072, China)

Abstract: Navigation is an indispensable part of people's daily lives, and getting lost during the navigation process is a common challenge. To this end, a Navigation Lost Knowledge Graph (NLKG) is constructed using navigation text data feedback from travel activities, aiming to understand navigation lost scenarios. Firstly, in order to achieve the usable scale of NLKG, more than 20 000 lost related texts were collected from the Weibo platform, and an artificial annotation corpus was constructed, covering over 10 000 high-quality entity annotations and more than 4 000 relationship annotations. Based on multidimensional information such as terrain, roads, and street environments, 25 types of entities and 20 types of relationships were defined, and the conceptual model of NLKG was established to achieve large-scale and structured knowledge expression. Secondly, a triplet joint extraction model NavLTR is proposed for navigation lost text, which comprehensively captures long-distance dependencies in sequence data, fully models complex relationships between navigation entities, automatically extracts entities and relationships related to lost experience, and constructs usable NLKG instances. Finally, based on NLKG, the importance analysis of lost factors, analysis of typical lost scenario factors, prediction of lost risk, correlation analysis of lost factors, and construction of an intelligent question answering agent system are conducted to demonstrate its application prospects and value. The experiment shows that the proposed method can effectively alleviate the scarcity problem of NLKG, providing a demonstration for integrating multi-source multimodal data to optimize navigation experience cognition, which is of great significance for optimizing navigation decisions and improving navigation experience.

Key Words: navigation lost; knowledge graph; navigation decision-making; space-time information extraction; multi-source data integration

收稿日期: 2025-07-24

基金项目: 国家自然科学基金项目(42071383)

作者简介: 陈虎(2001-), 男, 中国地质大学(武汉)计算机学院硕士研究生, 研究方向为自然语言处理、深度学习与城市交通智能计算; 杨林(1982-), 女, 博士, 中国地质大学(武汉)计算机学院副教授、硕士生导师, 研究方向为深度学习与城市交通智能计算、时空轨迹大数据分析与挖掘; 左泽均(1980-), 男, 博士, 中国地质大学(武汉)计算机学院副教授、硕士生导师, 研究方向为多源空间数据融合、地学信息可视化与时空分析; 罗明霞(2001-), 女, 中国地质大学(武汉)计算机学院硕士研究生, 研究方向为深度学习与城市交通智能计算。本文通讯作者: 杨林。

0 引言

导航决策在人们日常生活中扮演着至关重要的角色,是一项核心的认知任务。然而,在导航过程中存在迷路情况,给人们的出行带来了极大困扰。导航迷路现象频发,既影响出行效率,又加重了城市交通拥堵问题。由于迷路行为高度依赖个体对空间环境的认知加工,传统基于路径规划或位置匹配的方法难以对这类认知偏差行为进行建模与干预,因此迫切需要从认知理解层面深入刻画导航迷路场景。

导航迷路场景是指在导航过程中,由于环境复杂、信息缺失或认知偏差等因素,用户未能按照预期路径到达目标位置或对当前位置产生困惑的现象,表现包括:路径偏离、方向错误、原地徘徊等,具有较强的主观性与场景依赖性。为了确保研究的聚焦性与可操作性,在研究中设定以下约束条件:①语料数据主要来源于社交媒体平台,涵盖人们在自然出行活动中的第一人称导航迷路反馈;②研究对象为城市公共出行环境中的户外迷路情境,不包括室内导航、地下空间等特殊场景。本文通过分析导航迷路场景,挖掘导航经验数据中的关键信息,以深入理解引发迷路事件的因素,旨在为人们提供避免迷路的认知知识支持,提升导航决策的准确性和效率。

在大数据时代,导航经验数据极为丰富,源于用户与环境的互动,蕴含着宝贵的导航认知线索,代表了用户群体的共性导航经验认知。这些数据的主要来源是社交媒体,例如微博平台有大量以“迷路”为主题的帖子和评论,描述了各类人群发生迷路情形的特定场景信息(地点、天气、时间、交通方式等)。尽管,这些数据承载了大量的导航认知经验,但由于非结构化、语义复杂且缺乏统一模式,难以直接用于理解复杂的导航行为和认知偏差模式。为此,如何从海量导航迷路文本中提取关键认知要素并建立结构化表达,便成为了研究的首要挑战^[1]。

目前,手动从大量导航迷路文本中提取复杂的知识是一项耗时且主观性较强的操作,人工智能的高速发展使得自然语言处理技术(Natural Language Processing Technology, NLP)能高效地处理非结构化文本数据。通过NLP识别导航迷路文本中的实体和实体间的关系,可充分挖掘导航迷路场景的信息。研究表明,KG能有效存储结构化信息,实现高效的数据驱动发现,现已广泛用于查询和检索应用领域^[2]。KG是一种基于图结构的表示,以节点和边的形式表示实体和关系,从一个或多个来源获取关键信息,将其集成到知识库中,通过构建的节点和关系建立数据对象之间的连接,并通过推理技术生成新知识。本文研究以人们在导航过程中出现的导航迷路场景为基础,利用NLP整合导航经验数据中的核心迷路实体和关系构建导航迷路知识图谱(Navigation Lost Knowledge Graph, NLKG),

有助于理解和分析迷路因素,进而优化导航决策和改善导航体验,为整合多源多模态数据优化导航经验认知提供示范。

命名实体识别(Named Entity Recognition, NER)和关系提取(Relationship Extraction, RE)是构建NLKG的关键环节,包括:①基于规则和字典的方法^[3-4];②基于传统机器学习的方法^[5-6];③基于深度学习的方法^[7]。前两种方法需要大量的人工参与和特征工程,会导致资源和时间浪费,处理大规模语料库时存在性能瓶颈。随着深度学习技术的迅速发展,越来越多研究人员将深度学习用于信息提取任务。在地球科学领域,有许多研究实现了单个的NER或RE任务,但很少将两者结合在一起构建三元组。三元组通过(实体A,关系,实体B)的形式表达文本中实体与实体间的关系,不仅能将文本知识进行结构化存储,还有利于知识图谱的构建。

近年来,大多数研究先对话料库进行序列标注,再依次进行NER和ER任务,最后构建相关领域的知识图谱。然而,这种管道式的方法可能会导致错误累积,因为NER阶段产生的错误会直接传递到RE阶段,从而影响三元组的抽取精度^[8]。不同于管道式,联合式抽取方法以减少NER和RE任务间的传播误差为目的,通过一定的方式将两个任务整合在一起联合学习。通常情况下,联合式方法对三元组的抽取结果优于管道式方法,因此越来越多的研究人员开始研究三元组联合抽取方法,并在多个领域取得了良好的效果^[9]。然而,导航迷路文本具有主观性强、场景要素复杂、实体类型多样、语义边界模糊及上下文依赖性强等特点,现有方法仍然难以准确、高效地抽取关键导航知识。

综上,导航迷路领域的知识图谱构建仍存在一定的挑战,包括:①挖掘人们实施导航活动过程中形成的经验知识的研究十分缺乏,尚未发现面向导航迷路特定场景的知识表示研究,导航迷路场景下的迷路实体和关系概念模式亟待建立;②面向导航迷路场景的语料库稀缺,难以为模型提供充足的训练数据,导致抽取关键迷路实体和关系十分复杂;③现有导航文本数据繁杂、冗余,包含大量与导航迷路无关的内容,且迷路实体存在一定的重叠关系,使得现有模型在理解导航文本数据时存在限制,无法充分捕捉迷路场景相关的上下文信息及迷路实体间的关系,进而影响了三元组的抽取结果。

为此,本文提出面向导航迷路场景的知识图谱概念模式,针对现有导航迷路语料稀缺的问题收集了微博平台中近2万条包含“迷路”等关键词的出行文本。通过关键词过滤、主题分类等手段构建了一个涵盖典型迷路场景的导航迷路语料库,累计获得1万余个高质量实体标注和4000多条关系标注用于模型训练与评估,为NLKG的构建提供了坚实的数据基础,推动了导航迷路场景知识的系统建模。此外,提出一种新的联合式三元组抽取模型NavLTR

(Navigation Lost Triple Extraction),充分考虑了迷路场景的上下文和迷路实体依赖关系,可自动从导航迷路文本中抽取迷路三元组构建 NLKG,主要贡献如下:

(1)提出导航迷路知识图谱(Navigation Lost Knowledge Graph, NLKG)的概念模式,通过整合迷路环境地形、道路和街道环境等多维信息,建模导航迷路场景实体及关系,以适应导航迷路复杂场景应用分析需求;构建了人工标注的导航迷路实体语料库,从导航迷路相关场景的文本数据中分析实体特征及关系,并制定了关系的注释规范。

(2)提出基于导航迷路文本上下文的三元组联合抽取模型 NavLTR,融合 ERNIE、BiLSTM、self-attention 和 GCN 模块深度建模迷路实体间的复杂关系,以构建 NLKG 实例。

(3)在 NLKG 分类导航迷路场景中,开展迷路因素重要度、迷路风险预测和迷路因素关联性研究、智能问答 Agent 系统相关应用,为用户提供出行建议与优化决策。

1 相关工作

1.1 知识图谱

知识图谱作为一种结构化知识的表示方式,已广泛应用于信息检索、知识推理等任务中,能有效支持跨领域和特定领域的知识建模与发现。在地学领域,KG 已被用于建模时空信息。Yang 等^[10]在历史地图场景中构建了时空演化知识图谱,支持动态历史知识的查询。Du 等^[11]结合深度学习方法构建地理信息科学中的层次化 KG 模型,以增强地理实体之间的语义表达能力。Wang 等^[12]从地质报告中构建地质知识图谱,用于建模岩层演化与矿床成因过程。在城市研究领域,Liu 等^[13]提出一种城市知识图谱系统,融合城市多源数据构建面向城市计算的知识表达框架,助力城市管理与决策支持。

研究表明,KG 在地理与城市空间场景中具有广泛的应用价值。当前,研究聚焦于自然科学知识或实体地理要素的建模,缺乏对导航迷路场景认知数据的知识图谱构建方法。同时,导航迷路场景中涉及大量主观经验和复杂语义,知识结构难以通过传统地理 KG 方法建模,在支持个体化导航认知优化和城市微尺度路径规划等任务中存在一定的局限性。因此,构建面向导航迷路认知的专用知识图谱仍是一个亟待研究的关键问题。

1.2 命名实别与关系抽取

在知识图谱构建中 NER、RE 是核心任务,主要有 3 种方法:①基于规则和字典的方法在一定情况下提取的信息可能非常准确,但处理大规模数据时效率低下,难以覆盖每个实体和关系,泛化能力较弱;②传统机器学习方法中支持向量机(Support Vector Machine, SVM)、条件随机场(Conditional Random Field, CRF)、隐马尔科夫模型(Hidden Markov Model, HMM)和决策树(Decision Tree, DT)等

主要学习浅层特征,例如词和短语的形态特征。非深层次的语义理解依赖大量的特征工程和领域专家的知识,信息提取效率较低,限制了模型的通用性和可扩展性^[14-15];③基于深度学习的方法能自动识别、利用文本中的长距离依赖关系和上下文信息,无需进行繁琐的特征工程或依赖领域专家的知识。

目前,基于深度学习的方法已成为知识图谱构建中 NER、RE 任务的关键技术,在 NLP 领域发挥着重要作用。Qiu 等^[16]提出一种基于融合多特征和深度学习数据增强的模型,从地质文献中精准识别地质命名实体。Ma 等^[17]结合 BiLSTM 和 CRF 提出从社交媒体信息中准确识别中文地名的模型,在多个数据集上性能优异,体现了深度学习和预训练语言模型在处理复杂文本信息方面的潜力。Hu 等^[18]结合全球地名表和 Transformer 模型提出 GazPNE2 模型,成为了微博中提取地名的通用方法,在处理危机事件数据集上的性能较高。Zhou 等^[19]基于微调后的 BERT 模型和一维卷积神经网络的地名识别模块提出 TopoBERT,在多个数据集上进行调整和评估后,在地名识别任务中性能优秀,为各种地名识别任务提供了便捷的解决方案。Wang 等^[12]提出 GeoERE-Net 模型,从地质报告中实现了 NER 与 RE,以构建地质知识图谱。Wu 等^[20]针对地理领域的中文语料库数据,通过深度学习方法抽取地理空间关系。Qiu 等^[21]以矿产勘探数据为案例研究,从地矿报告中识别地质实体、抽取地质关系构建地矿知识图谱,为深层地质知识的探索提供了新视角和方法。Wen 等^[22]利用 BiLSTM 和 CFR 提出基于知识增强的 RE 方法。

尽管,在地理信息提取等特定领域中,NER 与 RE 任务已取得显著成果,但在导航迷路场景下的研究仍然不足。现有方法在该语境下面临多重挑战:①迷路文本多来自社交媒体,语言表达主观且模糊,实体类型不统一,实体边界识别难度较大;②迷路行为强依赖环境上下文,使抽取任务对上下文理解能力提出了更高要求;③导航迷路领域尚缺乏统一的概念模式和实体体系,导致知识结构稀疏,语义建模困难;④标注语料极其有限,难以满足监督学习模型对数据规模和质量的需求。由于上述问题共同制约了导航迷路知识的自动抽取与结构化表达,本文结合 NER 与 RE 技术设计了适应迷路文本特征的抽取方法,以实现关键导航知识的有效识别与 NLKG 构建。

1.3 三元组抽取

三元组抽取主要有管道式和联合抽取两种方式。其中,管道式独立训练实体识别和关系抽取两个子任务,但实体抽取阶段产生的误差无法得到及时纠正,会传递到关系抽取阶段,因此极易产生传播误差,影响三元组抽取的结果;联合抽取方式以减少传播误差为目的,联合建模实体识别和关系抽取任务,充分利用了实体和实体间的关系,构建了端到端的三元组抽取模型。

联合抽取方法通过各种依赖关系链接两个子任务模

Table 1 NLKG entity categories

表1 NLKG 实体类别

实体类别	描述	示例/类型
Location	迷路事件的地名	洪崖洞、解放碑
Region	迷路地点所属区域	重庆市、渝中区等区域类
POI	迷路地点所属POI	风景名胜、公园广场、学校
StreetImage	迷路地点街景	图像
Person	发生迷路的人员	老太太、游客
Weather	迷路事件发生的天气	暴雨、大雾
Time	迷路事件发生的时间	春季晚上、冬季凌晨
Vehicle	交通工具	自行车、地铁
Slope	迷路地点的坡度	连续数值
Aspect	迷路地点的坡向	连续数值
Relief	迷路地点的起伏度	连续数值
Curv	迷路地点的曲率	连续数值
Curvature	道路曲折度	连续数值
Roadtype	道路类型	城市主干道、城市支路
Length	道路长度	连续数值
Building	建筑物占比	连续数值
Person_streetview	人群占比	连续数值
Sidewalk	人行道占比	连续数值
Sky	天空占比	连续数值
Vegetation	植被占比	连续数值
Wall	墙占比	连续数值
Poi_richness	POI丰富度	连续数值
Terrain	地形	综合性实体
StreetEnvironment	街道环境	综合性实体
RoadCharacteristics	道路特征	综合性实体

特征,还能从实体关系图中挖掘深层语义,特别在多实体、多关系交织的场景中能为模型提供结构化的上下文支持,有助于提升关系抽取的准确性与表达广度。

改良后的模型主要由6个部分组成:

(1)ERNIE 词嵌入层。利用ERNIE对输入的文本进行切分得到相应的编码,通过式(1)得到每个词对应的向量用于模型后续编码。

$$i \in [1, N] h_i = E(w_i) \quad (1)$$

式中: N 为句子长度; E 为预训练模型ERNIE; i 为词在句子中的独热编码(one-hot)。

(2)BiLSTM与self-attention层。将ERNIE输出的编码向量作为输入,利用BiLSTM获取上下文信息。

$$H = \text{BiLSTM}(h_i) \quad (2)$$

由于文本中的关系信息可能出现在句子中的不同位置,BiLSTM虽能获取句子的局部特征信息,但无法确定哪些词对关系分类的作用更显著。self-attention不受词之间距离的限制计算依赖关系,允许模型在每个位置动态地聚焦序列中其他位置的信息,可捕获序列内部的复杂依赖关系。根据式(3)计算文本中不同位置对其他位置的贡献。

$$\text{Attention}(Q, K, V) = \text{soft max} \left(\frac{QK^T}{\sqrt{dk}} \right) V \quad (3)$$

式中: Q 、 K 、 V 矩阵由 H 通过线性变换得到; Q 代表目标位置想要关注的信息; K 用于与查询匹配以确定每个位置的重要性; V 为实际想要聚焦的内容; d 为矩阵 K 的维度,用于缩放点积结果。

Table 2 NLKG entity relations

表2 NLKG 实体关系

关系类别	描述	三元组示例
LostWeather	迷路地点和迷路天气的关联关系	(洪崖洞, LostWeather, 暴雨)
LostTime	迷路地点和迷路时间的关联关系	(解放碑, LostTime, 凌晨)
LostPerson	迷路人员和迷路地点的关联关系	(游客, LostPerson, 洪崖洞)
LostVehicle	迷路地点和交通工具的关联关系	(自行车, LostVehicle, 国家森林公园)
LostSlope	迷路地点和坡度的关联关系	(鹅岭公园, LostSlope, 连续数值)
LostAspect	迷路地点和坡向的关联关系	(鹅岭公园, LostAspect, 连续数值)
LostRelief	迷路地点和地形起伏度的关联关系	(鹅岭公园, LostRelief, 连续数值)
LostCurv	迷路地点和曲率的关联关系	(鹅岭公园, LostCurv, 连续数值)
LostCurvature	迷路地点和道路曲折度的关联关系	(鹅岭公园, LostCurvature, 连续数值)
LostRoadtype	迷路地点和道路类型的关联关系	(鹅岭公园, LostRoadtype, 连续数值)
LostLength	迷路地点和道路长度的关联关系	(鹅岭公园, LostLength, 连续数值)
LostBuilding	迷路地点和建筑物占比的关联关系	(鹅岭公园, LostBuilding, 连续数值)
LostPersonStreetview	迷路地点和人群占比的关联关系	(鹅岭公园, LostPersonStreetview, 连续数值)
LostSidewalk	迷路地点和人行道占比的关联关系	(鹅岭公园, LostSidewalk, 连续数值)
LostSky	迷路地点和天空占比的关联关系	(鹅岭公园, LostSky, 连续数值)
LostWall	迷路地点和墙占比的关联关系	(鹅岭公园, LostWall, 连续数值)
LostVegetation	迷路地点和植被占比的关联关系	(鹅岭公园, LostVegetation, 连续数值)
LostPoiRichness	迷路地点和POI丰富度的关联关系	(鹅岭公园, LostPoiRichness, 连续数值)
LocateAt	地理位置之间的包含关系	(洪崖洞, LocateAt, 渝中区)
BelongTo	实体间的附属关系	(大兴机场, BelongTo, 机场)

(3)主体抽取层。对BiLSTM与self-attention层的结果进行解码,构建两个二分类器。由式(4)、式(5)预测主体的开始和结束位置,计算每个词作为开始和结束的概率,并根据设定的阈值,大于阈值的标记为1,否则为0。

$$p_i^{\text{start_sub}} = \sigma(W_{\text{start}}x_i + b_{\text{start}}) \quad (4)$$

$$p_i^{\text{end_sub}} = \sigma(W_{\text{end}}x_i + b_{\text{end}}) \quad (5)$$

式中: x_i 为输入向量中第 i 个词的编码表示; W 为训练权值; b 为偏差; σ 为sigmoid激活函数; $p_i^{\text{start_sub}}$ 为输入向量中第 i 个词为主体的开始位置概率; $p_i^{\text{end_sub}}$ 为结束位置的概率。

(4)GCN层。GCN在图结构上应用卷积操作,使每个节点不仅包含自身的特征信息,还融合了其邻近节点的特征信息。该过程有助于模型捕捉实体间直接和间接关系,




Fig. 2 NavLTR architecture

图 2 NavLTR 架构

以及实体与其上下文间的相互作用。

$$H^{(l+1)} = \sigma(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W^{(l)}) \quad (6)$$

式中: H 表示第 l 层的节点特征矩阵; A 为图的邻接矩阵加上单位矩阵 I ; D 为图中每行元素之和构成的对角矩阵; W 为第 l 层的权重矩阵; σ 为激活函数。

(5) 客体标注层。类似于主体抽取, 客体标注由式 (7)、式 (8) 计算每个关系对应的客体标注。

$$p_i^{start_ob} = \sigma(W_{start}^r(x_i + v_{sub}^k) + b_{start}^r) \quad (7)$$

$$p_i^{end_ob} = \sigma(W_{end}^r(x_i + v_{sub}^k) + b_{end}^r) \quad (8)$$

式中: $p_i^{start_ob}$ 、 $p_i^{end_ob}$ 表示输入向量中第 i 个词被识别为客体的开始和结束位置的概率; v_{sub}^k 表示在主体抽取模块中检测到的第 k 个对象的编码表示向量。

(6) 损失函数。模型整体损失值为主体抽取任务和关系条件下, 客体抽取任务两个任务的损失之和, 如式 (9) 所示。

$$L = \sum_{s \in T_j} \lg p_\theta(s|x) + \sum_{s \in T_j} \lg p_{\varphi_r}(o|s, x) \quad (9)$$

式中: L 为句子中的潜在三元组。

2.3 多源知识整合

NLKG 的构建不仅依赖于文本中结构化信息的抽取, 还要融合其他外部异构知识源以增强图谱的完整性与表达能力。本文通过 NavLTR 从导航迷路文本中提取迷路地点、迷路人员、迷路天气、迷路时间、交通工具等核心实体

和关系。对于迷路地点坡度、坡向、地形起伏度、地点曲率、道路曲折度、道路类型、道路长度、建筑物占比和人群占比等多种关键迷路因素实体, 将通过 DEM 数据开放平台 (<https://search.earthdata.nasa.gov>)、OSM 路网平台 (<https://www.openstreetmap.org>) 和百度地图 (<https://lbsyun.baidu.com/>) 等获得。

本文通过 DEM 数据表示地形类实体, 例如坡度、坡向、地形起伏度和曲率。其中, 坡度反映了地表的倾斜程度或陡峭程度; 坡向反映了地表的倾斜方向或朝向; 地形起伏度反映了地表高程的变化幅度和频率; 形曲率反映了地表在水平方向上的曲率程度, 即地表轮廓的弯曲程度。首先, 获取以迷路地点为中心的 500×500 m 的高程数据; 其次, 通过 ArcGIS 工具计算每个地形类实体的值, 计算公式如式 (10)~式 (13) 所示。

$$\text{Slope} = \arctan \left(\sqrt{\left(\frac{\partial z}{\partial x} \right)^2 + \left(\frac{\partial z}{\partial y} \right)^2} \right) \quad (10)$$

式中: $\frac{\partial z}{\partial x}$ 、 $\frac{\partial z}{\partial y}$ 为高程在水平和垂直方向上的变化率。

$$\text{Aspect} = \arctan 2 \left(\frac{\partial z}{\partial y}, -\frac{\partial z}{\partial x} \right) \quad (11)$$

式中: $\frac{\partial z}{\partial x}$ 、 $\frac{\partial z}{\partial y}$ 为高程在水平和垂直方向上的变化率。

$$\text{Relief} = z_{\max} - z_{\min} \quad (12)$$

式中: $z_{\max}$ 、 $z_{\min}$ 表示最大高程、最小高程。

$$\text{Curvature} = \frac{\partial^2 z}{\partial x^2} + \frac{\partial^2 z}{\partial y^2} \quad (13)$$

式中, $\frac{\partial^2 z}{\partial x^2}$ 、 $\frac{\partial^2 z}{\partial y^2}$ 为高程在 x 、 y 方向上的二阶变化率。

本文通过 OSM 路网数据表示道路类实体,例如道路曲折度、道路长度、道路类型。根据式(14)计算以迷路地点为中心半径 1 000 m 范围内的道路网络曲折度。同时,根据路网中出现的频率、复杂度,将道路划分为高架、快速路、城市主干路、城市次干路、城市支路、郊区乡村道路、人行道路和自行车道等类型。

$$\text{Curvature} = \sum_{i=1}^n l_i \times C_i \quad (14)$$

式中: n 表示区域内道路段的总数量; l_i 为第 i 个道路段的长度; C_i 为第 i 个道路段的曲折等级。

通过百度地图获取 POI 数据、街景数据来表示迷路地点环境类实体,例如 POI 丰富度、建筑物占比、植被占比和人群占比等。具体地,以迷路地点为中心半径 1 000 m 范围内的所有 POI 数据计算迷路地点的丰富度指数,如式(15)所示。

$$\text{Poi_richness} = \frac{s - 1}{\ln n} \quad (15)$$

式中: s 为区域内 POI 类型的数量; n 为区域内 POI 的数量。

首先,采用 PSPNet 模型分割街景图像中的语义要素,提取建筑物占比、植被占比和人群占比等实体。PSPNet 是一种基于卷积神经网络的图像语义分割模型,通过分类图像中的像素,将图像分割成不同的语义区域,以多尺度的方式捕获图像的全局信息。其次,由于单一的迷路地名在表达迷路地点的地理位置信息时通常会显得模糊和不完整,本文将通过百度平台获取迷路地点的从属区域实体,加强模型对迷路的理解与分析,例如洪崖洞—渝中区—重庆表达洪崖洞位于重庆,渝中区位于重庆的知识。最后,为了使知识图谱中的迷路因素数据能用于后续知识图谱推理计算,基于专家经验和样本数据对所有因素进行标准化处理。

3 实验结果与分析

3.1 数据集

本文数据集由两部分构成:一部分是前文提及的多源知识数据;另一部分来源于微博社交媒体,包括迷路相关的文本信息。其中,微博平台包含了丰富的迷路场景信息,涉及迷路地点、当事人、发生时间、天气状况及交通方式等要素,对模型训练和构建初步的导航迷路知识图谱至关重要。在实验前,基于一定规则对上述文本数据进行清洗、整理及标注工作,形成了适用于模型训练的语料库,并将数据集以 6:2:2 的比例划分训练集、验证集和测

试集。

3.2 实验环境与参数设置

硬件环境为: RTX4070 GPU, 32 GB 内存。软件环境为: Windows 10, Torch 2.0.1, Python 3.11。模型参数如表 3 所示。

Table 3 Model parameters

表 3 模型参数

类别	数值
Learning_rate	e^{-5}
Epochs	10
Batch_size	8
Dropout	0.1
BiLSTM_hidden_dim	768
GCN_dim	768
Heads	12

3.3 评价指标

本文使用准确率(P)、召回率(E)、F1 值作为评价指标,其中 F1 为主要的评价指标。实验中,预测正确与错误是针对模型抽取出的三元组而言,只有当三元组中的主体、关系、客体全部预测正确时,才认定该三元组预测结果正确。

$$P = \frac{Tp}{Tp + Fp} \quad (16)$$

$$R = \frac{Tp}{Tp + FN} \quad (17)$$

$$F1 = \frac{2PR}{P + R} \quad (18)$$

式中: TP 表示正类判定为正类的个数; FP 表示负类判定为正类的个数; FN 表示正类判定为负类的个数。

3.4 迷路文本实体与关系抽取结果

为了验证 NavLTR 在导航迷路文本中的有效性,选取 6 个具有代表性的基线方法进行比较实验,涵盖管道式与联合式两类方法。其中,管道式方法采用文献[29]提出的典型方案,在命名实体识别阶段使用 BERT-BiLSTM-CRF,在关系抽取阶段使用 BERT 进行分类;联合式方法包括 5 种主流模型: CasRel、PRGC、SpERT、TPLinker 和 UIE,分别代表基于序列标注、全局指针、片段抽取、表格填充和生成式的联合抽取策略,实验结果如表 4 所示^[24-28]。由此可知,NavLTR 的准确率、召回率和 F1 相较于比较模型最高,分别为 94.14%、94.35% 和 94.25%,证明了该模型能精准地从迷路文本中提取三元组。

管道式方法的抽取结果并不理想,准确率、召回率分别为 69.09%、82.70%,F1 得分仅为 75.28%,相较于 NLTE 相差接近 20%,原因为管道式两个子任务独立运行会产生传播误差,影响三元组的抽取结果。相较于管道式,联合式方法抽取结果虽有明显提升但不及 NLTE。相较于 SpERT, NLTE 在 F1 指数上高出 11.03%,原因为基于片段的分类方式会导致模型语义表征能力较弱,缺乏文本中的先验信息,且 SpERT 在训练时所用的数据集较少,模型泛

Table 4 Triple extraction results of different models			
表 4 不同模型的三元组抽取结果 (%)			
Methods	Precision	Recall	F1-score
Pipeline	69.09	82.70	75.28
SpERT	78.00	89.19	83.22
TPlinker	90.62	91.03	90.82
CasRel	90.34	91.12	90.73
PRGC	90.67	91.62	91.15
UIE	91.56	91.68	91.62
Ours	94.14	94.35	94.25

化能力不佳。

TPlinker、CasRel、PRGC、UIE 模型的准确率、召回率和 F1 指数都达到了 90% 以上,但均不及 NLTE。其中,CasRel 主要是为了解决三元组重叠问题,通过 BERT 对输入语句执行矢量编码,再使用 sigmoid 函数识别主题实体的头部和尾部位置,最后根据识别出的主体实体判断特定关系下的对象实体,从而将关系和对象实体作为一个集合输出,保证三元组抽取的完整性。例如,“2023 年春季晚上,热心群众报警称,有一个男孩在曙光小区迷路”中“曙光小区”实体出现在多个三元组中,该模型能准确提取(曙光小区,迷路时间,春季晚上)和(曙光小区,迷路人员,男孩)两个三元组。

TPlinker 旨在解决三元组重叠和暴露偏差问题,暴露偏差(Exposure Bias)就是指训练时每个输入都来自于真实样本的标签,测试时输入却来自上一个时刻的输出。TPlinker 将联合抽取看作 Token Pair Linking Problem 并提出 handshaking tagging scheme,构造了一个 1+2×N 的全局

信息矩阵(N为关系类别数)和一个抽取所有 Subject 和 Object 的矩阵。同时,对于每个关系构建两个矩阵,分别为 subject head to object head (SH-to-OH) 和 subject tail to object tail (ST-to-OT),利用 handshaking tagging scheme 实现实体和关系对齐,解码出三元组,但因构建了大量的关系矩阵,冗余信息将导致标签稀疏和收敛速度降低,实体和关系之间也缺乏深度的交互和关联,在一定程度上影响了模型训练性能。

PRGC 基于 CasRel 和 TPlinker 进行了改良,通过潜在关系过滤部分关系,虽降低了计算复杂度,但有可能会導致抽取出的三元组不完整。采用 BIO 方式标注数据,在抽取 Subject、Object 时加入了与关系类型相关的向量以提升模型泛化能力,但要求召回率足够高,否则误差将不可逆。

UIE 将 NER、RE 等任务进行统一建模,自适应地生成目标结构,并从不同的知识源中学习通用信息,虽降低了解码复杂度,但基于生成式的 UIE 在生成 token 序列时可能会出现缺少 token 位置信息等情况,因此模型在处理三元组重叠问题时可能会出现遗漏,导致三元组抽取不完整。

3.5 迷路地点实体消歧

由于中国地名存在多样性问题,同一地点可能因为简称而呈现出不同的表达方式,例如“大兴机场”和“大兴国际机场”、“重庆洪崖洞”和“洪崖洞”,将导致模型提取出的地名实体存在重叠、定义模糊等问题,如表 5 所示。考虑到“百花小区南门”“曙光小区北门”这种带有精确描述的地名实体对迷路的影响,在实体消歧时会适当保留地名描述。

Table 5 Entity relationship extraction result of the lost text			
表 5 迷路文本的实体关系抽取结果			
Sentence	Subject	Object	Relation
真的不行了,浦东机场真的太大了,直接迷路,亲身体会到了一些什么晕头转向!夏季下午	浦东机场	夏季下午	迷路时间
2022年春季晚上22点,一位老人独自来到浦东国际机场,神情恍惚,疑似迷路,在里面转了好久好久,工作人员立即上前询问,提供帮助	浦东国际机场	老人 春季晚上	迷路人员 迷路时间
夏季晚上,今天还发生了件可笑的事情,在洪崖洞玩,从一楼到十一楼全是地面,导致失联半小时,上完卫生间之后出来就迷路了,重庆就是这么神奇的城市	洪崖洞	夏季晚上	迷路时间
尽管有导航,但是无数游客还是在重庆洪崖洞迷路,山路十八弯走到你心酸	重庆洪崖洞	游客	迷路人员
2023年春季晚上,热心群众报警称,有一个男孩在曙光小区迷路,请求民警帮助	曙光小区	男孩 春季晚上	迷路人员 迷路时间
2023年冬季早上,大雾,导航去曙光小区北门,没想到却迷路了,果真导航是不认识东南西北的大门的	曙光小区北门	大雾 冬季早上	迷路天气 迷路时间

综上,本文使用一种充分利用全局语义信息的端到端图神经实体消歧模型进行实验。首先,针对需要消歧的迷路文本构建异构实体词图,以模拟同一文档中候选实体之间的全局语义关系;其次,将图神经网络应用于实体词图中,生成具有全局语义增强的实体嵌入;最后,利用 CRF 进行消歧^[30]。实体消歧前后的结果如表 6 所示。

Table 6 Results before and after disambiguation of lost location	
表 6 迷路地点消歧前后结果	
消歧前	消歧后
浦东机场、浦东国际机场、上海浦东国际机场	上海浦东国际机场
洪崖洞、洪崖洞民俗风貌区、重庆洪崖洞	洪崖洞
.....	

4 具体应用

4.1 迷路因素重要度分析

本文深入分析了迷路因素在NLKG中的节点重要度,旨在识别对迷路影响最显著的因素,并利用图计算进一步量化各因素的影响力。同时,为了识别影响迷路最显著的因素,使用图计算方法量化迷路因素在NLKG中的节点重要度。具体地,基于节点的加权重中心性进行分析,节点的重要度由节点被引用的加权频次决定,计算方法包括权重赋值和度中心性计算。

(1)权重赋值。各节点的权重由其量化值决定,该值反映了同一因素不同取值对迷路的影响程度。

(2)度中心性计算。基于整个NLKG,计算每个因素的

加权重中心性,如式(19)所示。

$$Cw_D(i) = \sum_{j \in M(i)} w_{ij} \quad (19)$$

式中: $Cw_D(i)$ 表示节点*i*的加权重中心性; $M(i)$ 为与节点*i*直接相连的节点集合; w_{ij} 为节点*i*、*j*之间边的权重。

图3表示节点重要度结果,节点大小反映了节点的重要程度。由此可见,地点的曲率、坡度、起伏度、时间、POI丰富度、人群占比、人行道占比、植被占比、建筑物占比、道路长度是影响迷路的关键因素,即在地形复杂、街道环境复杂、视野受限的情况下迷路事件最容易发生。此外,考虑到交通工具类因素不便于量化分析的特殊性(数值大小难以体现其对迷路的影响程度),将对其单独分析,例如在“南京新街口”坐地铁、在“成都绕城绿道”骑自行车的迷路事件发生的频率较高。




Fig. 3 Importance of lost factors

图3 迷路因素重要度

4.2 典型迷路场景因素分析

在迷路因素分析中场景划分具有重要的意义,在不同的场景下,同一因素对迷路的影响程度并非一致,人们可能会因为不同的因素而迷路。例如,游客可能因景区人群拥挤而迷路,司机可能因缺少道路指示标志的指引而迷路,因此分析不同场景的特点可更精确地识别和理解特定环境中影响迷路的关键因素。具体地,将迷路地点划分为风景名胜、交通设施服务、科教文化服务、商业服务、住宅、政府机构等6个类别,采用加权重中心性方法评估每个场景迷路因素的重要度,为特定场景下的迷路预防提供针对性的见解。

图4为各场景下迷路因素重要度分析结果。由此可见,对于景区类地点,曲率、坡度、POI丰富度、时间和人群密集程度的影响最为显著,表明地形复杂性、景区丰富性、视野受限程度及人流量是导致游客迷路的关键;对于交通

类的地点,天空可见性、墙面占比、道路曲折度、道路长度等因素占比较大,表明建筑结构和道路设计对交通类地点的影响较大;对于商业类的地点,人群密集程度、POI丰富度、建筑物占比、时间等是引发迷路的重要因素。

综上,不同场景下迷路因素的特点不同,这些发现对城市建设、导航设计具有重要的指导意义。例如,在地形复杂的景区增设指示标志、优化游览路线、人流引导方案;在交通类地点增设高可见的路标和指示牌,针对道路曲折度高的地方优化导航策略;在复杂的商业区开发高效的导航辅助工具,例如数字导览和AR导航、优化人流控制措施和商业布局;在住宅区和政府机构区域注重行人道路系统的完善和绿化环境的优化等。

4.3 迷路风险预测

本文在分析迷路场景因素重要度后,提出迷路风险的概念,用于衡量一个地方发生迷路事件的概率,并进一步




图 4 不同场景的迷路因素重要度

建立了一个计算迷路风险的模型。首先,统计迷路事件在各省份的分布比例,在各省会城市主干道上随机选取一定的非迷路地点;其次,将得到的因素重要度与迷路正负样本结合,分析各迷路因素在迷路地点和非迷路地点中的表现,计算出该条件下迷路事件发生的概率,当给定地点和迷路因素时,模型会根据各因素的重要度及其量化值计算迷路风险。

如果给定的迷路因素不完整时,模型会根据已知条件进行计算,再综合考虑未知因素的影响,预测该地点在某些条件下发生迷路的概率,实验结果如表 7 所示。由此可知,该模型在迷路正负样本上取得了较好的效果,F1、AUC 指数最低分别为 78.26%、86.76%。该预测模型不仅加深了对迷路事件的理解,还为迷路预防和管理提供了一种有效的工具,在导航系统优化、城市规划、旅游管理等方面具有重要的应用价值,能有效预防迷路事件的发生。

4.4 迷路因素关联性分析

本文基于 Apriori 算法的节点关联规则挖掘方法,深入研究了 NLKG 中不同迷路因素之间的潜在关联性,旨在了解特定场景下,不同因素相互组合是否对迷路风险具有显著的增加作用。具体为,基于已构建的 NLKG,在因素节点间引入新的边来表示因素之间的复合关系,例如坡度和坡向的组合关系,结合图计算与 Apriori 算法探索因素节点间的频繁模式和强关联规则。其中,图计算可有效处理和分析复杂的节点关系;Apriori 算法用于识别这些关系中的频繁项集和高置信度规则。

通过计算节点间的提升度,可挖掘迷路事件中常出现

Table 7 Model prediction results

表 7 模型预测结果

场景类型	样本类型	Precision	Recall	F1-score	AUC
		/%	/%	/%	/%
总体	负样本	91.11	94.37	92.71	95.64
	正样本	92.69	88.57	90.58	
风景名胜	负样本	94.29	91.67	92.96	96.97
	正样本	92.31	94.74	93.51	
交通设施服务	负样本	83.12	92.75	87.67	91.51
	正样本	89.58	76.79	82.69	
科教文化服务	负样本	91.43	94.12	92.57	93.91
	正样本	92.59	89.29	90.91	
商业服务	负样本	86.96	80.00	83.33	95.41
	正样本	88.37	92.68	90.48	
住宅	负样本	87.90	94.78	91.21	94.67
	正样本	92.86	83.87	88.14	
政府机构	负样本	83.33	88.24	85.71	86.76
	正样本	81.82	75.00	78.26	

的因素组合。例如,在各类场景下,坡度、坡向、起伏度等地形因子间存在相关性;在交通类地点,天空占比和建筑物占比、道路曲折度和道路长度、人群占比和 POI 丰富度间存在相关性;在景区类地点,植被占比和天空占比、道路曲折度和地形曲率间存在相关性;在住宅类地点,建筑物占比和人群占比、人群占比和天空占比间存在相关性。

综上,迷路因素关联性分析为理解迷路事件的复杂性提供了新的视角,通过识别和解释迷路因素之间的关联性,不仅加深了人们对导航迷路的动态理解,还为设计更有效的导航辅助系统和预防策略提供了有价值的理论

依据。

4.5 智能问答 Agent 系统

为了充分发挥 NLKG 的应用潜力,从静态问答系统向动态认知 Agent 系统转变,开发了一个事件感知型智能导航 Agent。该系统基于 NLKG、图计算引擎及语言大模型,能识别、响应“导航迷路事件”,并与用户进行多轮交互,联动外部资源提供决策建议,旨在实现更高层次的出行认知支持。具体而言,Agent 系统具备以下核心能力:

(1)知识图谱检索与智能问答。用户可提出问题:“第一次自驾重庆,有哪些注意事项?”“南京有哪些容易迷路的地段?”“我现在在解放碑,接下来该怎么走?”系统首先识别用户意图并将其结构化图谱查询任务,随后调用 NLKG 与外部资源融合推理,最终以图示与自然语言反馈查询结果,如图 5 所示。由此可见,系统准确反馈了重庆多个迷路高发区域,结合导航经验知识给出了出行建议。




Fig. 5 NLKG query example

图 5 NLKG 查询示例

(2)知识图谱联动推理与语义计算。在 NLKG 支持下,系统可处理复杂问题,例如“哪些地方类似于我现在的位置?”“这类场所的迷路概率是多少?”“是否应换一种交通方式?”等。实践表明,结合图相似度分析、路径依赖预测、迷路因子共现分析后,系统可提供解释性强、上下文一致的导航建议。

(3)外部资源对接与智能推荐。该系统能联动第三方开放接口(地图导航、天气预报、POI检索、交通服务等),实现多源数据融合。例如,当用户表达“我在南山找不到路”时,系统可结合用户定位、实时天气、地形结构和 NLKG 知识,综合生成路径建议或风险提示。

(4)事件识别与主动触发。系统通过分析导航文本或用户语音输入的语义,自动识别导航迷路相关的行为模式(“我找不到入口”“好像走反了”等),判断是否发生迷路事件。一旦事件被触发,Agent 会主动接入用户交互流程,启动位置识别、信息检索与风险分析任务。

综上,通过构建 Agent 系统,不仅实现了用户对迷路知识的主动查询,还能实时感知与动态响应迷路事件。未

来,该 Agent 系统可嵌入导航软件、城市大脑平台或移动终端,支持个性化路径规划、风险提示、语义问答和行为干预,在认知层面提升导航系统的智能化水平,优化用户出行体验。

5 结语

本研究提出一种新的实体关系联合抽取模型,能从迷路文本中抽取以迷路地点为主体的三元组,并以此构建 NLKG。首先,基于微博社交媒体中的迷路文本,采用一定的规则对其进行清洗和标注,构建了迷路样本的语料库;其次,在 CasRel 模型的基础上结合 ERNIE、BiLSTM、self-attention 和 GCN 解决现有模型存在的问题,提升了三元组抽取的完整性和准确性。

由于迷路文本中涉及的迷路实体具有一定的局限性,本文通过 OSM 和 DEM 等第三方平台,整合了坡度、坡向、地形起伏度、地点曲率、道路曲折度、道路类型、道路长度、建筑物占比、人群占比等关键迷路因素实体。同时,考虑

到中国地名的歧义性,对模型抽取的地名实体进行了实体消歧,减少了NLKG的冗余性。此外,本文还基于已构建的NLKG,从整体、场景划分的角度分析了迷路因素的重要度;基于因素重要度分析了预测迷路风险;分析了迷路因素间的关联性;开发了导航迷路智能问答Agent系统,充分证明了NLKG的价值与意义。

然而,本文研究仍存在一些局限性:语料库较单一,主要来源为微博,暂未纳入其他社交平台的迷路文本;迷路地点多针对城市内部,未涵盖所有迷路场景。未来,将考虑整合多平台的迷路样本,调研、收集城市范围外的迷路地点信息,进而构建更全面的导航迷路知识图谱。

参考文献:

- [1] ZAMINI M, REZA H, RABIEI M, et al. A review of knowledge graph completion[DB/OL]. <https://arxiv.org/abs/2208.11652>.
- [2] GOHSEN M, STEIN B. Assisted knowledge graph authoring: human-supervised knowledge graph construction from natural language[DB/OL]. <https://arxiv.org/pdf/2401.07683>.
- [3] NANDINI P, JAIRAM B G. Named entity recognition: a review for key information extraction[J]. *Lecture Notes in Networks and Systems*, 2023, 608:427-437.
- [4] JIANG J, LIN R, ZOU H. Power domain named entity recognition based on rules and dictionaries[C]// 22nd International Conference on Communication Technology, 2022:1898-1902.
- [5] WANG Y, ZHAO W T, WAN Y, et al. Named entity recognition via machine reading comprehension [DB/OL]. <https://arxiv.org/abs/2309.11027>.
- [6] SHELKE R, VANJALE S. Review based on named entity recognition for hindi language using machine learning approach[J]. *Smart Innovation, Systems and Technologies, Smart Innovation, Systems and Technologies*, 2022, 290:333-340.
- [7] SHALINI S, REETESH K S, PIYUSH P S. Advancements in named entity recognition using deep learning techniques: a comprehensive study on emerging trends[J]. *International Journal of Advanced Research in Science, Communication and Technology*, 2023, 25(6):356-362.
- [8] JIANG B, CAO J. Joint extraction of entities and relations via entity and relation heterogeneous graph attention networks[J]. *Applied Sciences*, 2023, 13(2):842.
- [9] SUI D B, CHEN Y B, LIU K, et al. Joint entity and relation extraction with set prediction networks[DB/OL]. <https://arxiv.org/abs/2011.01675>.
- [10] YANG Y Q, CAO M, KONG D H, et al. An entity alignment approach coupling NGBoost and SHAP for constructing spatio-temporal evolution knowledge graph from historical atlases[J]. *International Journal of Geographical Information Science*, 2024, 38(8): 1-18.
- [11] DU J X, WANG S H, YE X Y, et al. GIS-KG: building a large-scale hierarchical knowledge graph for geographic information science[J]. *International Journal of Geographical Information Science*, 2022, 36(5): 873-897.
- [12] WANG B, WU L, XIE Z, et al. Understanding geological reports based on knowledge graphs using a deep learning approach[J]. *Computers & Geosciences*, 2022, 168:105229.
- [13] LIU Y, DING J T, FU Y J, et al. Urbankg: an urban knowledge graph system[J]. *ACM Transactions on Intelligent Systems and Technology*, 2023, 14(4): 1-25.
- [14] TUO M M, YANG W Z, et al. Review of entity relation extraction[J]. *Journal of Intelligent & Fuzzy Systems*, 2023, 44(5):1-15.
- [15] GHARAGOZLOU H, MOHAMMADZADEH J, ABASTANFARD, et al. Semantic relation extraction: a review of approaches, datasets, and evaluation methods with looking at the methods and datasets in the persian language[J]. *ACM Transactions on Asian and Low-Resource Language Information Processing*, 2023, 22(7):1-29.
- [16] QIU Q J, TIAN M, HUANG Z, et al. Chinese engineering geological named entity recognition by fusing multi-features and data enhancement using deep learning[J]. *Expert Systems with Applications*, 2024, 238: 121925.
- [17] MA K, TAN Y J, XIE Z, et al. Chinese toponym recognition with variant neural structures from social media messages based on BERT methods[J]. *Journal of Geographical Systems*, 2022, 24(2):143-169.
- [18] HU X K, ZHOU Z Y, SUN Y, et al. GazPNE2: a general place name extractor for microblogs fusing gazetteers and pretrained transformer models[J]. *IEEE Internet of Things Journal*, 2022, 9(17):16259-16271.
- [19] ZHOU B, ZOU L, HU Y J, et al. TopoBERT: a plug and play toponym recognition module harnessing fine-tuned BERT[J]. *International Journal of Digital Earth*, 2022, 16(1):3045-3063.
- [20] WU K H, ZHANG X Y, DANG Y L, et al. Deep learning models for spatial relation extraction in text[J]. *Geo-Spatial Information Science*, 2022, 26(1):58-70.
- [21] QIU Q J, MA K, LYU H R, et al. Construction and application of a knowledge graph for iron deposits using text mining analytics and a deep learning algorithm[J]. *Mathematical Geosciences*, 2023, 55:423-456.
- [22] WEN C J, JIA X D, CHEN T. Improving extraction of Chinese open relations using pre-trained language model and knowledge enhancement[J]. *Data Intelligence*, 2023, 5(4):962-989.
- [23] YANG B, CARDIE C. Joint inference for fine-grained opinion extraction[C]// 51st Annual Meeting of the Association for Computational Linguistics, 2013:1640-1649.
- [24] WEI Z P, SU J L, WANG Y, et al. A novel cascade binary tagging framework for relational triple extraction[DB/OL]. <https://arxiv.org/abs/1909.03227>.
- [25] ZHENG H Y, WEN R, CHEN X, et al. PRGC: potential relation and global correspondence based joint relational triple extraction[C]// Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing, 2021:6225-6235.
- [26] EBERTS M, ULGES A, et al. Span-based joint entity and relation extraction with transformer pre-training[DB/OL]. <https://arxiv.org/abs/1909.07755>.
- [27] WANG Y C, YU B W, ZHANG Y Y, et al. TPLinker: single-stage joint extraction of entities and relations through token pair linking[C]// 28th International Conference on Computational Linguistics, 2020: 1572-1582.
- [28] FEI H, WU S Q, LI J Y, et al. Lasuie: unifying information extraction with latent adaptive structure-aware generative language model[DB/OL]. <https://arxiv.org/abs/2304.06248>.
- [29] QIU Q J, XIE Z, WU L, et al. BiLSTM-CRF for geological named entity recognition from the geoscience literature[J]. *Earth Science Informatics*, 2019, 12:565-579.
- [30] SHAO Z, MA Y X. The disambiguation strategy of knowledge fusion for domain knowledge graph. in lecture notes in electrical engineering[C]// Proceedings of International Conference on Image, Vision and Intelligent Systems, 2022:944-952.

(责任编辑:刘嘉文)