

中文引用格式:邵舒羽,张杨,刘艳.基于KGCN的地质地震灾害事件演化结果预测[J].中国安全科学学报,2025,35(2):212-219.

英文引用格式:SHAO Shuyu, ZHANG Yang, LIU Yan. Prediction of geological earthquake disaster event evolution results based on KGCN [J]. China Safety Science Journal, 2025, 35(2): 212-219.

基于KGCN的地质地震灾害事件演化结果预测*

邵舒羽^{1,2}副教授,张杨^{1,2},刘艳^{1,2}教授

(1 北京物资学院 物流学院,北京 101149;2 北京市物流系统与技术重点实验室,北京 101149)

中图分类号:X915.5

文献标志码:A

DOI: 10.16265/j.cnki.issn1003-3033.2025.02.0516

基金项目:国家自然科学基金资助(82102176);北京市社会科学基金资助(21GCL040)。

【摘要】 为提高地质地震灾害事件预测的准确性和可靠性,提出一种结合知识图谱和图卷积神经网络(GCN)的预测模型。首先,构建地质地震灾害事件的知识图谱,将灾害相关的多源信息整合成结构化数据;然后,利用知识图谱卷积网络(KGCN)模型,对知识图谱中的实体和关系进行深度学习,挖掘潜在的关联规则,从而预测灾害的演化结果;最后,通过地质地震灾害事件案例集验证模型的有效性。结果表明:结合知识图谱和GCN的预测模型在地质地震灾害事件演化结果预测方面展现出显著效果,特别是在处理复杂的多源数据时,模型能够高效整合信息,准确挖掘潜在关联,在灾害等级、伤亡等级、承灾体类别等多个方面的预测准确率均表现优异,尤其是在灾害应急响应等级的预测上,准确率达到89.92%。

【关键词】 知识图谱卷积网络(KGCN); 地质地震灾害; 灾害事件; 演化结果; 知识图谱; 图卷积神经网络(GCN)

Prediction of geological earthquake disaster event evolution results based on KGCN

SHAO Shuyu^{1,2}, ZHANG Yang^{1,2}, LIU Yan^{1,2}

(1 School of logistics, Beijing Wuzi University, Beijing 101149, China;

2 Beijing Logistics System and Technology Key Laboratory, Beijing 101149, China)

Abstract: To enhance the accuracy and reliability of geological earthquake disaster events predictions, a predictive model combining knowledge graph with GCN was proposed. Initially, the knowledge graph for geological earthquake disaster events was constructed, and the multi-source disaster-related information was consolidated into structured data. Then, the KGCN model was employed for deep learning of entities and relationships within the knowledge graph, uncovering potential association rules to forecast the evolution of disasters. Finally, the effectiveness of the model was validated through a set of geological earthquake disaster cases. The results show that the predictive model combining knowledge graphs with GCN exhibits excellent effectiveness in forecasting the evolution of geological earthquake disaster events, especially in dealing with complex multi-source data. The information can be efficiently integrated, and potential relationships can be accurately uncovered by the model. Excellent prediction accuracy is achieved in various aspects, including disaster levels, casualty levels, and disaster victim categories. Notably, the

accuracy in predicting the disaster emergency response levels reaches 89.92%.

Keywords: knowledge graph convolutional network (KGCN); geological earthquake disaster; disaster event; evolutionary result; knowledge graph; graph convolution neural network(GCN)

0 引言

《“十四五”国家综合防灾减灾规划》指出,我国自然灾害易发频发,防灾减灾救灾工作面临新形势新挑战。地质地震灾害作为制约区域经济发展和威胁人民生命财产安全的重要因素,严重影响了我国经济社会的可持续发展^[1]。由于灾害事件的演化趋势和发展态势涉及多个复杂因素的相互作用^[2],因此,需要系统性地理解因素之间的关联,揭示灾害演化的机制和特征^[3]。

随着人工智能和大数据技术的快速发展,灾害事件演化结果预测已成为降低灾害损失、保障人民生命财产安全的关键环节。目前灾害事件演化的预测方法有基于知识图谱、情景推演、决策支持模型等^[4-5],在灾害预测领域取得了初步成果。但是,在面对不同形式的数据库时,往往需要多个数据库或表格进行关联,数据管理较为复杂,且难以实现多模态数据和跨领域数据的大规模互联^[5]。灾害事件演化结果预测方法智能化程度不高,过分依赖决策者主观设定的特征权重及检索模板,导致提取复杂、预测准确性低且应用性较弱^[6]。因此,寻求新的预测方法和技术手段,提高预测的准确性和可靠性,成为当前灾害研究领域亟待解决的问题。

在数据管理、多模态数据和跨领域数据互联、预测智能化程度等方面,众多学者展开了深入研究,如邱芹军等^[7]通过海量地学数据构建地质灾害链知识图谱,结构化表达灾害事件与应急响应资源信息,实现数据-信息-知识的转换,有助于应急救援资源信息的整合与共享;陶坤旺等^[8]基于自然灾害相关知识,提出面向一体化综合减灾的知识图谱构建方法,总结和剖析知识图谱在应急减灾领域的构建流程和应用情况;樊润宇等^[9]针对灾害文献中命名实体形式多样、语义模糊、上下文不确定等问题,提出结合多分支双向门控循环单元层和条件随机场模型的深度多分支模型,可有效识别地质灾害相关研究文献中的实体;杜志强等^[10]提出自顶向下和自底向上相结合的自然灾害应急知识图谱构建方法,实现了从多源数据到互联知识的转化。

综上,知识图谱能够有效整合和表示多领域、多

来源的信息,为灾害预测提供丰富的数据基础,但不能作为事件演化结果预测的工具。而图卷积神经网络(Graph Convolution Neural Networks,GCN)能够有效利用图结构数据,挖掘节点之间的复杂关系和全局结构信息,可实现对知识图谱的深度学习和分析^[11]。因此,笔者提出基于知识图谱卷积网络(Knowledge GCN,KGCN)的预测方法,融合知识图谱和GCN的双重优势,全面捕捉与事件相关的各类信息并进行有效的结构化处理,挖掘节点之间的潜在关系,预测灾害事件的演化结果。并通过地质地震灾害事件案例集进行验证,以期对灾害防范与减灾工作提供有力的技术支持。

1 KGCN 模型概述

1.1 知识图谱构建

知识图谱以三元组(头实体、关系、尾实体)的形式描述表现实体及其之间的关系,涉及类目定义、实体识别与关系抽取、图谱构建等多个关键步骤,其构建流程如图1所示。其中,本体层是对知识的一种规范化、系统化的描述,通过确定本体类目及类目之间的关系,梳理数据源的内容结构及其关联关系。数据层则是知识图谱中存储实例知识数据的地方,该部分主要进行知识获取,即从各种原始数据源(如结构化数据库、半结构化网页、非结构化文本等)中抽取与目标领域相关的实体、关系及属性信息。此外,数据层还负责确保数据的准确性和完整性。




图1 知识图谱构建流程

Fig.1 Knowledge graph construction process

1.2 GCN

GCN是一种利用卷积来提取空间特征的图神经网络(Graph Neural Network,GNN)^[12],通过聚合节点及其邻居的特征信息,能够学习到图中节点和

边的复杂关系。与传统的卷积神经网络 (Convolutional Neural Network, CNN) 不同, GCN 能够处理非欧几里得空间的数据, 其每一个卷积层的传播规则如下:

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

式中: $\tilde{\mathbf{A}}$ 为无向图 G 的邻接矩阵加上自连接, $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}_N$, \mathbf{I}_N 为单位矩阵; $\tilde{\mathbf{D}}$ 为 $\tilde{\mathbf{A}}$ 的度矩阵, 即 $\tilde{D}_{ii} = \sum_j \tilde{A}_{ij}$; $\mathbf{H}^{(l)}$ 为第 l 层的激活单元矩阵, $\mathbf{H}^0 = \mathbf{X}$; $\mathbf{W}^{(l)}$ 为每一层的参数矩阵; σ 为非线性激活函数。

GCN 在处理图结构数据时, 通过卷积层聚合网络中节点及邻居的信息, 根据归一化拉普拉斯矩阵的性质向邻居分配权重, 利用图的邻接关系, 将邻居节点的特征信息融合到中心节点, 从而更新中心节点的特征。GCN 模型实现图卷积操作的过程如下^[13]:

对于包含顶点的集合和边的集合的无向图 $G = (V, E)$, 归一化的拉普拉斯矩阵为:

$$\mathbf{L} = \mathbf{I}_n - \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} \quad (2)$$

式中: \mathbf{A} 为图 G 的邻接矩阵; \mathbf{D} 为顶点的度矩阵。

由于 \mathbf{L} 半正定, 则 \mathbf{L} 可以进行谱分解:

$$\mathbf{L} = \mathbf{U} \mathbf{\Lambda} \mathbf{U}^T \quad (3)$$

$$\mathbf{U}^{-1} = \mathbf{U}^T \quad (4)$$

式中 \mathbf{U} 的列向量两两正交。

再使用 \mathbf{L} 及其特征向量定义傅里叶变换:

$$\mathbf{F}(\boldsymbol{\lambda}_l) = \hat{\mathbf{f}}(\boldsymbol{\lambda}_l) = \sum_{i=1}^N \mathbf{f}(i) \mathbf{u}_l(i) \quad (5)$$

式中: $\mathbf{f}(i)$ 与图中顶点位置相对应; $\mathbf{u}_l(i)$ 为第 l 个特征向量的第 i 个分量。

\mathbf{f} 在图上的傅里叶变换就是与特征向量 \mathbf{u}_l 做内积运算, 得到傅里叶变换的矩阵形式:

$$\hat{\mathbf{f}} = \mathbf{U}^T \mathbf{f} \quad (6)$$

推广到傅里叶逆变换的矩阵形式为:

$$\mathbf{f}(i) = \sum_{l=1}^N \hat{\mathbf{f}}(\boldsymbol{\lambda}_l) \mathbf{u}_l(i) \quad (7)$$

根据卷积定理, 函数 \mathbf{f} 和 \mathbf{h} 的卷积结果等于傅里叶变换后相乘的逆变换:

$$\begin{aligned} \mathbf{f} \mathbf{h} &= \mathbf{F}^{-1} [\hat{\mathbf{f}}(\mathbf{w}) \hat{\mathbf{h}}(\mathbf{w})] \\ &= \frac{1}{2\pi} \int \hat{\mathbf{f}}(\mathbf{w}) \times \hat{\mathbf{h}}(\mathbf{w}) e^{i\mathbf{w}t} d\mathbf{w} \end{aligned} \quad (8)$$

则 \mathbf{f} 与卷积核 \mathbf{g} 的卷积为:

$$(\mathbf{f} \times \mathbf{g})_c = \mathbf{U} \text{diag}(\mathbf{g}(\boldsymbol{\lambda}_l)) \mathbf{U}^T \mathbf{f} \quad (9)$$

式中 $\text{diag}(\mathbf{g}(\boldsymbol{\lambda}_l))$ 为图卷积操作的参数。

在深度学习中, 设 $\mathbf{g}\theta(\mathbf{A})$ 为卷积核, 则令

$$\mathbf{g}\theta(\mathbf{A}) = \text{diag}(\mathbf{g}(\boldsymbol{\lambda}_l)) = \sum_{j=0}^{K-1} \mathbf{a}_j \mathbf{A}^j \quad (10)$$

卷积层的输出为:

$$\mathbf{y} = \delta(\mathbf{U} \mathbf{g}\theta(\mathbf{A}) \mathbf{U}^T \mathbf{x}) \quad (11)$$

又因:

$$\mathbf{U} \mathbf{g}\theta(\mathbf{A}) \mathbf{U}^T = \sum_{j=0}^{K-1} \mathbf{U} \mathbf{a}_j \mathbf{A}^j \mathbf{U}^T = \sum_{j=0}^{K-1} \mathbf{a}_j \mathbf{L}^j \quad (12)$$

$$\mathbf{y}_o = \delta\left(\sum_{j=0}^{K-1} \mathbf{a}_j \mathbf{L}^j \mathbf{x}\right) \quad (13)$$

式中: K 为卷积核个数; $(\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_{K-1})$ 为任意参数。

引入切比雪夫多项式简化计算, 可得 GCN 最终模型为:

$$\mathbf{H}^{l+1} = \mathbf{A} \mathbf{H}^l \mathbf{W} \quad (14)$$

$$\mathbf{A} = \mathbf{I}_N + \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} \quad (15)$$

1.3 KGCN

KGCN 包含知识图谱和 GCN 这 2 部分, 其核心组件和层次结构主要围绕图的节点和边展开, 在输入层接收以知识图谱为表现形式的图结构数据, 隐藏层通过多层卷积层来捕获输入层中的节点和边信息。在卷积层中, 每个节点的表示都会通过聚合其邻居节点的信息来更新, 从而增强节点特征的代表能力。最后, 输出层根据隐藏层提取的特征, 预测事件演化结果。KGCN 事件演化结果预测流程如图 2 所示。




图 2 KGCN 事件演化结果预测流程

Fig. 2 KGCN event evolution result prediction process

KGCN 事件演化结果预测模型通过训练 GCN 模型来预测事件演化结果。首先, 在构建地质地震灾害事件知识图谱的基础上, 通过 KGCN 将地质地震灾害事件知识图谱作为输入层; 其次, 通过多层 GCN 传播和聚合知识图谱中的节点 (实体) 和边 (关系), 提取每个实体的邻域信息, 形成特征表示, 然后, 对于特定的预测任务 (如灾害等级预测), 使用

实体特征表示作为输入,通过全连接层等神经网络结构进行决策制定;最后,模型输出的预测结果可直接与知识图谱中的实体和关系相关联。并且该模型能够融合多源异构信息,处理不确定性和复杂性问题,并提供可解释性强的预测结果。

2 基于地质地震灾害的知识图谱构建

2.1 自然灾害分类

根据《自然灾害分类与代码》(GB/T 28921—2012)和《自然灾害承灾体分类与代码》(GB/T 32572—2016),筛选其中的自然灾害和承灾体并将其作为实体,自然灾害节点表见表 1。把自然灾害划分为气象水文、地质地震、海洋、生物和生态环境共 5 类灾害,简称灾类。其中,气象水文灾害分为 12 类灾种、地质地震灾害分为 9 类灾种、海洋灾害分为 6 类灾种、生物灾害分为 6 类灾种、生态环境灾害分为 5 类灾种,共将灾类划分为 40 种灾害。

表 1 自然灾害节点

Table 1 Natural disaster node

灾类	种类
气象水文灾害	干旱
	洪涝
	台风
	暴雨
	大风
	冰雹
	低温
	冰雪
	高温
	沙尘暴
	大雾
	其他气象水文
地质地震灾害	地震
	火山
	崩塌
	滑坡
	泥石流
	地面塌陷
	地面沉降
	地裂缝
	其他地质
海洋灾害	风暴潮
	海浪
	海冰
	海啸
	赤潮
	其他海洋

续表 1

生物灾害	种类
	植物病虫害
	疫病
	鼠害
	草害
	赤潮
生态环境灾害	森林/草原火灾
	水土流失
	风蚀沙化
	盐渍化
	石漠化
其他生态环境	

2.2 地质地震灾害事例定义及描述

以地质地震灾害为研究重点,其特征信息为灾害城市、天气情况(晴天、阴天、雨天、雪天、雾天)和致灾因子。其中,致灾因子包括地震灾害、火山灾害、崩塌灾害、滑坡灾害、泥石流灾害、地面塌陷灾害、地面沉降灾害、地裂缝灾害、其他地质灾害,共 9 种灾种。地质地震灾害事件结果信息定义及描述见表 2。承灾体受灾关系词见表 3。

表 2 地质地震灾害事件结果信息定义及描述

Table 2 Geological earthquake disaster event result information definition and description

结果信息	描述
承灾体类别	人、消费品、房屋、设施和设备、产品、原料、资源、环境
灾害等级	特别重大、重大、较大、一般
伤亡等级	0、1、2、3、4、5
灾害应急响应等级	I 级、II 级、III 级和 IV 级
持续时长/h	0~12、12~36、36~72、72 以上
衍生灾害	火灾、水灾、泥石流、瘟疫、爆炸、毒气泄漏、放射性物质扩散

表 3 承灾体受灾关系词

Table 3 Disaster-bearing relation glossary

承灾体类别	描述关系词
人	伤亡
消费品	损失
房屋	倒损
施和设备	损坏
产品	减产
原料	损失
资源	破坏
环境	污染

国家地质地震应急预案将地质地震灾害分为特别重大、重大、较大、一般4个等级,对应地质地震灾害应急响应分为Ⅰ级、Ⅱ级、Ⅲ级和Ⅳ级。按照不同的灾害应急响应等级,进行人员搜救、开展医疗救治和卫生防疫、抢修基础设施、安置受灾群众、加强现场监测、防御次生灾害、开展社会动员、维护社会治安、发布信息、加强涉外事务管理、开展灾害调查与评估、应急结束等,详细内容以《国家自然灾害救助应急预案》为准。

2.3 数据层

文中数据来源于国家自然灾害防治研究院、国家减震网、国家标准全文公开系统等公开数据源,共收集到3 279条以文本形式呈现地质地震灾害实例。数据层构建的关键步骤是数据抽取,涉及到从数据源中提取出实体、关系、属性等信息。对于结构化数据,可直接通过数据库查询等方式获取,对于非结构化数据和半结构化数据,则需要借助自然语言处理、图像处理等技术进行信息抽取^[14]。

实体识别依赖于自然语言处理技术从文本中自动识别出具有特定性质的实体信息,利用已有的双向变换器模型,根据灾害特点制定规则和模板来匹配和提取文本中的实体信息。利用命名实体识别技术识别原始非结构化或半结构化的数据,共提取出灾害名称、灾害城市、天气情况、致灾因子、承灾体类别、灾害等级、伤亡等级、灾害应急

响应等级、持续时长、衍生灾害10种地质地震相关实体。

关系抽取是指在非结构或半结构化数据中识别出主体与客体之间的关系,形成实体关系三元组。关系抽取主要分为2个任务,①关系分类,基于预先给定的关系对实体进行分类匹配;②开放关系抽取,直接从文本中抽取结构化文本关系,将文本关系映射到知识库的规范关系。根据地质地震灾害领域的特点,制定关系抽取的规则和模板,对非结构化数据进行关系抽取,当与设定的模板相匹配时,根据制定的规则模板提取出实体之间的关系,共抽取到9种“实体-关系-实体”三元组关系:(灾害名称)-(“灾害城市”)-(灾害城市)、(灾害名称)-(“天气情况”)-(天气情况)、(灾害名称)-(“致灾因子”)-(致灾因子)、(灾害名称)-(“承灾体类别”)-(承灾体类别)、(灾害名称)-(“灾害等级”)-(灾害等级)、(灾害名称)-(“伤亡等级”)-(伤亡等级)、(灾害名称)-(“灾害应急响应”)-(灾害应急响应)、(灾害名称)-(“持续时长”)-(持续时长)、(灾害名称)-(“衍生灾害”)-(衍生灾害)。

2.4 地质地震灾害知识图谱可视化

使用Py2neo库将经过处理的结构化数据存储到Neo4j数据库中,并完成包括10种实体和9种关系的地质地震灾害知识图谱的构建,具体构建流程如图3所示。

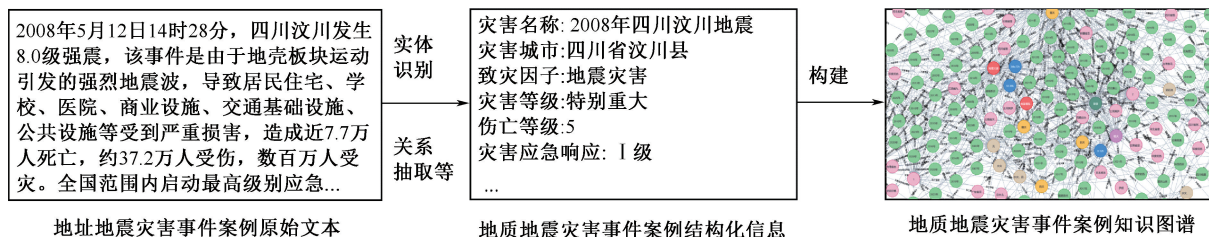


图3 地质地震灾害事件案例知识图谱构建流程

Fig. 3 Construction process of case knowledge map of geological earthquake disaster events

完成数据存储后,通过Cypher语句可查询地质地震灾害知识图谱中的特定实体和关系,并以图的形式展示实体之间的关系网络。例如:通过Cypher语句MATCH(n:-灾害名称-{name:'2008年四川汶川地震'})RETURN n查询灾害名称节点“2008年四川汶川地震”,查询结果如图4所示。

3 地质地震灾害事件演化结果预测

3.1 地质地震灾害事件演化结果预测模型构建

KGCN地质地震灾害事件演化结果预测模型在

地质地震灾害知识图谱构建完成的基础上,将知识图谱作为GCN的输入来训练事件演化结果预测模型,模型预测步骤如图5所示。

首先,将地质地震灾害事件案例知识图谱中的实体映射成实值向量,并融合所有邻域实体特征及关系特征。使用DistMult知识图谱嵌入模型进行打分,将关系向量 r 对角化变成对角矩阵,作为线性变换矩阵,变换矩阵将头实体向量映射到尾实体向量^[15],公式为:

$$f(h, r, t) = e_h^T R e_t \quad (16)$$

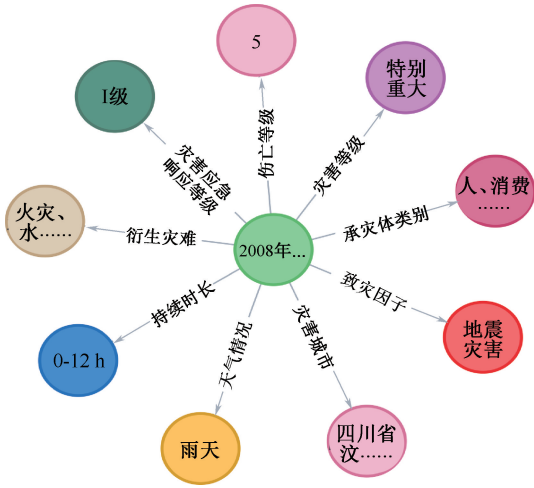


图 4 单个实体节点查询示例

Fig. 4 Example of querying a single entity node

式中: e_h, e_t 分别为头实体和尾实体的向量; R_r 为关系 r 的矩阵向量。

归一化打分结果,其中,打分结果最高 3 元组的尾实体认为其为真,即灾害事件最有可能的演化结果。模型的损失函数为:

$$L = \sum_{(i,j) \in Y(i,j \in N_d, j \neq i)} -y_{i,j} \lg f(\mathbf{h}, \mathbf{r}, \mathbf{t}) - (1 - y_{i,j}) \lg(1 - f(\mathbf{h}, \mathbf{r}, \mathbf{t})) \quad (17)$$

式中 y 为一个指标集,如果是正样本,则 $y = 1$,如果是负样本,则 $y = 0$ 。

3.2 地质地震灾害结果预测试验及结果分析

3.2.1 试验过程

将收集到的 3 279 条地质地震灾害实例按 3 : 1 : 1 的比例划分为训练集(1 969 条)、验证集(655 条)和测试集(655 条)。以准确率为性能评价

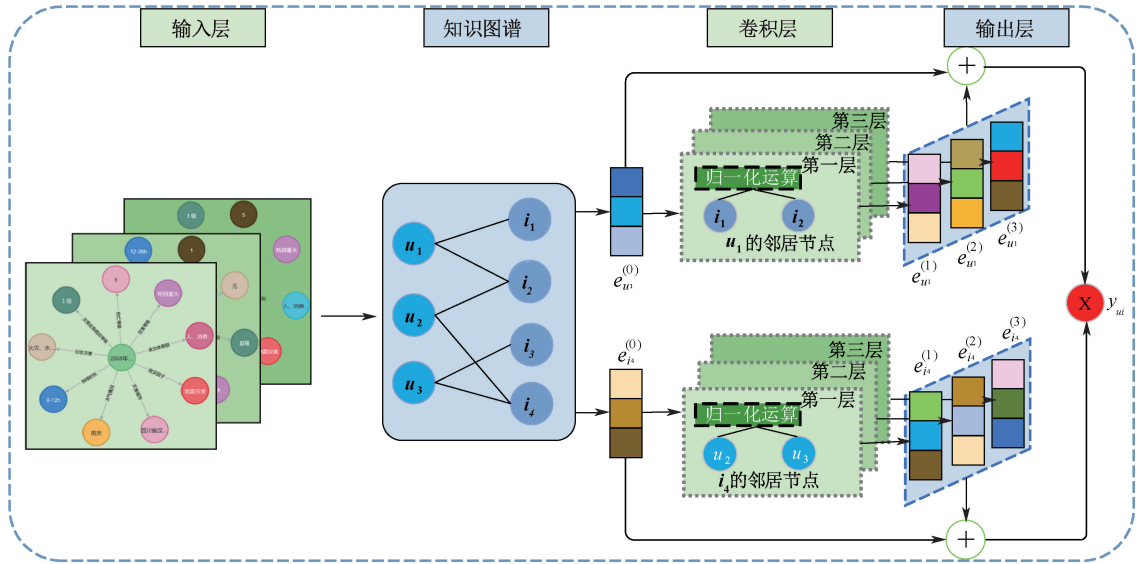


图 5 KGCN 事件演化结果预测步骤

Fig. 5 KGCN event evolution prediction steps

指标,损失函数为交叉熵函数,梯度下降方法利用的 Adam 优化算法,本文采用地质地震灾害实例作为试验数据集,从收集到的 3 279 条实例中提取出 9 种关系、26 232 个三元组,构建地质地震灾害事件案例知识图谱,如图 6 所示。

3.2.2 灾害事件预测试验结果及验证

地质地震灾害事件预测试验结果见表 4,由表 4 可知:KGCN 模型无论是在灾害等级、伤亡等级还是衍生灾害的预测,均能提供相对准确的预测结果,除承灾体类别外,其他预测结果的准确率均达到 80% 及以上,尤其是灾害应急响应等级的预测准确率达到 89.92%,表明 KGCN 模型具有良好的泛化性能。

表 4 地质地震灾害事件预测结果

Table 4 Prediction results of geological earthquake disaster events

结果信息	准确率/%
灾害等级	83.38
伤亡等级	86.30
承灾体类别	77.50
灾害应急响应等级	89.92
持续时长	81.75
衍生灾害	80.38

为验证 KGCN 模型的有效性,使用 GNN、CNN、三支决策的 GNN(Three-way Decision-, TWD-GNN)、多层感知器(Multiple Perceptron, MLP)这 4 种模型预




图6 地质地震灾害事件案例知识图谱(部分)

Fig. 6 Case Knowledge map of geological earthquake disaster events (part)

测地质地震灾害测试数据集并对比,预测流程与KGCN模型一致,不同模型预测准确率对比结果见表5。

由表5可知:在相同数据集及参数下,由于CNN对于非图结构数据的处理能力有限,MLP无法直接利用节点间的复杂关系等原因,CNN、MLP模型预测的准确率较低。虽然GNN、TWD-GNN能够

捕捉复杂数据之间的关系,但由于GNN缺乏结构化知识表示,TWD-GNN在模型构建和参数调整上较为复杂,相比KGCN的模型预测的准确率仍然较低。而KGCN模型既捕捉了复杂数据之间的关系,又进一步挖掘了知识图谱中的潜在关联和规律,验证KGCN模型在该问题上的性能优势。

表5 不同模型预测准确率对比

Table 5 Comparison of prediction accuracy of different models

预测模型	准确率					
	灾害等级	伤亡等级	承灾体类别	灾害应急响应	持续时长	衍生灾害
GNN	61.66	63.17	58.43	65.31	57.99	58.13
CNN	38.49	40.01	32.60	35.75	39.11	38.52
TWD-GNN	67.28	65.99	61.46	74.13	69.42	59.86
MLP	41.21	38.37	34.62	41.35	38.21	38.82
KGCN	83.38	86.30	77.50	89.92	81.75	80.38

4 结论

1) 采用实体识别和关系抽取技术,将非结构化和半结构化的地质地震灾害文本转化为结构化格式,构建10种实体和9种关系的地质地震灾害知识图谱。

2) 通过KGCN模型提取和学习图谱特征,挖掘

灾害事件的潜在关联规则,有助于准确预测地质地震灾害事件的灾害等级、伤亡等级、承灾体类别等演化结果。

3) 未来将扩展知识图谱的范围,涵盖更多的灾害类型和相关因素,结合其他机器学习或深度学习方法,构建混合模型以进一步提高预测性能。

参考文献

- [1] 白鹏飞, 谭小虎, 侯蕊芳. 社会网络视角下地质灾害应急处置合作关系[J]. 中国安全科学学报, 2024, 34(4): 207-216.
BAI Pengfei, TAN Xiaohu, HOU Ruifang. Geohazard emergency response partnerships from a social network perspective[J]. China Safety Science Journal, 2024, 34(4): 207-216.
- [2] 郑石明, 宋悦. 灾害治理组织网络的演化机理: 一个“结构-过程-价值”整合性分析框架[J]. 中国地质大学学报: 社会科学版, 2024, 24(3): 100-113.
ZHENG Shiming, SONG Yue. The evolution mechanism of disaster governance organizational networks: an integrated "structure, process, and value" analysis framework [J]. Journal of China University of Geosciences: Social Sciences Edition, 2024, 24(3): 100-113.
- [3] 陈长坤, 戴琦乐, 余荣付, 等. 基于灾害演化网络的泥石流风险评估方法研究[J]. 灾害学, 2024, 39(2): 62-66.
CHEN Changkun, DAI Qile, YU Rongfu, et al. Research on risk assessment method of debris flows based on disaster evolution network [J]. Journal of Catastrophology, 2024, 39(2): 62-66.
- [4] 于峰, 樊博. “情景-结构-要素”视角下复杂灾害治理的情报协同体重构[J]. 情报理论与实践, 2024, 47(6): 154-165.
YU Feng, FAN Bo. Intelligence collaboration system reconstruction for complex disaster governance under the perspective of "scenario-structure-element" [J]. Information Studies: Theory and Application, 2024, 47(6): 154-165.
- [5] 尤薇佳, 孟芸竹, 杨跃翔, 等. 基于突发事件应对标准的知识图谱构建及应用研究[J]. 情报理论与实践, 2023, 46(11): 164-173.
YOU Weijia, MENG Yunzhu, YANG Yuexiang, et al. Construction and application of the knowledge graph based on emergency response standards [J]. Information Studies: Theory and Application, 2023, 46(11): 164-173.
- [6] 陈囿任, 李勇, 温明, 等. 多模态知识图谱融合技术研究综述[J]. 计算机工程与应用, 2024, 60(13): 36-50.
CHEN Youren, LI Yong, WEN Ming, et al. Research and comprehensive review on multi-modal knowledge graph fusion techniques [J]. Computer Engineering and Applications, 2024, 60(13): 36-50.
- [7] 邱芹军, 吴亮, 马凯, 等. 面向灾害应急响应的地质灾害链知识图谱构建方法[J]. 地球科学, 2023, 48(5): 1 875-1 891.
QIU Qinjun, WU Liang, MA Kai, et al. A knowledge graph construction method for geohazard chain for disaster emergency response [J]. Earth Science, 2023, 48(5): 1 875-1 891.
- [8] 陶坤旺, 赵阳阳, 朱鹏, 等. 面向一体化综合减灾的知识图谱构建方法[J]. 武汉大学学报: 信息科学版, 2020, 45(8): 1 296-1 302.
TAO Kunwang, ZHAO Yangyang, ZHU Peng, et al. Knowledge graph construction for integrated disaster reduction [J]. Geomatics and Information Science of Wuhan University, 2020, 45(8): 1 296-1 302.
- [9] FAN Runyu, WANG Lizhe, YAN Jining, et al. Deep learning-based named entity recognition and knowledge graph construction for geological hazards [J]. ISPRS International Journal of Geo-Information, 2019, 9(1): DOI: 10.3390/ijgi9010015.
- [10] 杜志强, 李钰, 张叶廷, 等. 自然灾害应急知识图谱构建方法研究[J]. 武汉大学学报: 信息科学版, 2020, 45(9): 1 344-1 355.
DU Zhiqiang, LI Yu, ZHANG Yeting, et al. Knowledge graph construction method on natural disaster emergency [J]. Geomatics and Information Science of Wuhan University, 2020, 45(9): 1 344-1 355.
- [11] 刘俊奇, 涂文轩, 祝恩. 图卷积神经网络综述[J]. 计算机工程与科学, 2023, 45(8): 1 472-1 481.
LIU Junqi, TU Wenxuan, ZHU En. Survey on graph convolutional neural networks [J]. Computer Engineering and Science, 2023, 45(8): 1 472-1 481.
- [12] 齐杰, 王中辉, 李驿言. 基于图卷积神经网络的道路网匹配[J]. 测绘通报, 2023(12): 19-24, 44.
QI Jie, WANG Zhonghui, LI Yiyang. Road network matching based on graph convolutional neural network [J]. Bulletin of Surveying and Mapping, 2023(12): 19-24, 44.
- [13] 朱广宇, 张萌, 裔扬. 基于知识图谱的城市轨道交通突发事件演化结果预测[J]. 电子与信息学报, 2023, 45(3): 949-957.
ZHU Guangyu, ZHANG Meng, YI Yang. Prediction of evolution results of urban rail transit emergencies based on knowledge graph [J]. Journal of Electronics and Information Technology, 2023, 45(3): 949-957.
- [14] 段雨希, 邱芹军, 田苗, 等. 面向地质图的知识图谱构建及智能问答应用[J]. 地质科学, 2024, 59(2): 588-602.
DUAN Yuxi, QIU Qinjun, TIAN Miao, et al. Geological map-oriented knowledge graph construction and intelligent Q&A application [J]. Geological Science, 2024, 59(2): 588-602.
- [15] 张金斗, 李京. 一种结合层次化类别信息知识图谱表示学习方法[J]. 软件学报, 2022, 33(9): 3 331-3 346.
ZHANG Jindou, LI Jing. Knowledge graph embedding combining with hierarchical type information [J]. Journal of Software, 2022, 33(9): 3 331-3 346.

作者简介: 邵舒羽 (1989—), 男, 河南周口人, 博士, 副教授, 主要从事应急物流、人因工程、应急管理方面的研究。E-mail: shaoshuyu@bwu.edu.cn。