



计算机科学

COMPUTER SCIENCE

基于多视角IB的安全风险关系抽取研究

李希望, 曹培松, 吴俞颖, 郭淑明, 余维

引用本文

李希望, 曹培松, 吴俞颖, 郭淑明, 余维. 基于多视角IB的安全风险关系抽取研究[J]. 计算机科学, 2025, 52(5): 330-336.

LI Xiwang, CAO Peisong, WU Yuying, GUO Shuming, SHE Wei. [Study on Security Risk Relation Extraction Based on Multi-view IB](#) [J]. Computer Science, 2025, 52(5): 330-336.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[改进U-Net的多尺度特征融合遥感图像语义分割网络](#)

Improved U-Net Multi-scale Feature Fusion Semantic Segmentation Network for RemoteSensing Images

计算机科学, 2025, 52(5): 212-219. <https://doi.org/10.11896/jsjcx.240300137>

[基于多尺度融合注意力的多视角文档图像篡改检测与定位](#)

Multi-view and Multi-scale Fusion Attention Network for Document Image Forgery Localization

计算机科学, 2025, 52(4): 327-335. <https://doi.org/10.11896/jsjcx.240100142>

[话题性话语标记的自动识别与分类](#)

Automatic Identification and Classification of Topical Discourse Markers

计算机科学, 2025, 52(4): 255-261. <https://doi.org/10.11896/jsjcx.240100155>

[一致块对角和限定的多视角子空间聚类算法](#)

Consistent Block Diagonal and Exclusive Multi-view Subspace Clustering

计算机科学, 2025, 52(4): 138-146. <https://doi.org/10.11896/jsjcx.240100131>

[融合词间句间多关系建模的评论推荐算法](#)

Joint Inter-word and Inter-sentence Multi-relationship Modeling for Review-based Recommendation Algorithm

计算机科学, 2025, 52(4): 119-128. <https://doi.org/10.11896/jsjcx.240700053>

基于多视角 IB 的安全风险关系抽取研究

李希望¹ 曹培松¹ 吴俞颖¹ 郭淑明^{2,3} 余维^{1,2}

1 郑州大学网络空间安全学院 郑州 450000

2 嵩山实验室 郑州 450000

3 国家数字交换系统工程技术研究中心 郑州 450000

(350071532@qq.com)

摘要 安全风险是保障安全的核心任务,传统识别安全风险的方法已经不能满足智能化发展的需求。关系抽取是安全风险识别的方法之一,研究关系抽取对安全风险识别具有重要意义。尽管现有的模型已经取得了较好的性能,但是大多数现有的关系抽取模型忽略了领域实体表征不足的问题,并且数据中存在较多不相关信息。针对该问题,提出了一个基于多视角 IB (Information Bottleneck) 的安全风险关系抽取模型 MIBRE (Multi-view Information Bottleneck for Relation Extraction),它通过融合多视角语义信息来达到增强领域实体语义的目的。这两个视角分别是文本视角和图像视角。为了最大化获取两个视角之间的相关信息,基于信息瓶颈方法构造了一个目标函数,在压缩两个视角信息的同时最大化地保留了相关信息。在两个真实的铁路领域数据集上的实验表明,MIBRE 识别的 F1 值分别达到了 64.28% 和 74.34%,相较于基于异构图的 LGGCN 模型 F1 值分别提升了 4.41% 和 2.98%,相较于基于注意力机制的 TDGAT 模型 F1 值分别提升了 1.89% 和 1.53%。实验结果验证了所提模型在安全风险识别上的有效性。

关键词: 关系抽取; 信息瓶颈; 多视角; 安全风险; 特征融合

中图分类号 TP391

Study on Security Risk Relation Extraction Based on Multi-view IB

LI Xiwang¹, CAO Peisong¹, WU Yuying¹, GUO Shuming^{2,3} and SHE Wei^{1,2}

1 School of Cyber Science and Engineering, Zhengzhou University, Zhengzhou 450000, China

2 Songshan Laboratory, Zhengzhou 450000, China

3 National Digital Switching System Engineering & Technological R&D Center, Zhengzhou 450000, China

Abstract Safety risk management is the core assignment to ensure safety, and the traditional methods of identifying safety risks can no longer meet the needs of intelligent development. Research on relation extraction is of significant importance for security risk management, as it serves as one of the methods for identifying security risks. However, most existing relation extraction models ignore the problem of insufficient representation of domain entity and contain more noise in the data. To address the above problems, a multi-view IB-based safety risk relation extraction model (MIBRE) is proposed. Specifically, it achieves enhanced domain entity semantics by fusing semantic information from multi-view. In order to obtain the maximum relevant information between the two views, an objective function is constructed using the information bottleneck approach. The relevant information is maximally preserved and restored while compressing the information between the two views. Experiments on two real domain datasets show that the F1 value recognized by MIBRE reaches 64.28% and 74.34% respectively, which is 4.41% and 2.98% higher than that of LGGCN based on heterogeneous graph model. Compared with TDGAT based on attention mechanism model, F1 value increased by 1.89% and 1.53% respectively. The effectiveness of the proposed model in security risk identification is verified by experiments.

Keywords Relation extraction, Information bottleneck, Multi-view, Safety risk, Feature fusion

到稿日期:2024-03-25 返修日期:2024-08-16

基金项目:国家重点研发计划(31703-3);嵩山实验室预研项目(YYYY022022003)

This work was supported by the National Key Research and Development Program of China(31703-3) and Songshan Laboratory Pre-research Project(YYYY022022003).

通信作者:余维(wshe@zsu.edu.cn)

1 引言

随着智能信息化和互联网的快速发展与变革,多元异构、组织结构松散的大数据形成了一个巨大的知识网^[1],亟需从中探索和挖掘符合人类认知的互联信息。通过构建知识互联的智能知识网络,以新的知识表示和管理形式应用知识,是学术界和工业界在人工智能领域的研究热点。从大量非结构化文本数据中抽取潜在的安全风险至关重要,因为这些数据可能包含关键的情报和线索,可以帮助识别和预防潜在的安全威胁。这也是构建结构化知识的重要一步。结构化知识有助于推动智能安全风险管理的不断发展。近年来,在学术界和工业界,知识图谱的广泛应用引起了普遍关注^[2],如英语知识图谱、微软知识图谱和 Yago 等。在信息检索领域,这些知识图谱取得了不错的成果。然而,目前对特定领域的知识图谱的研究还相对较少。

构建知识图谱的基本任务之一是关系抽取,其目的是提取自然语言句子中所有可能的关系三元组(主语、谓语、宾语)^[3]。该任务作为构建知识图谱的上游任务,发挥着重要的作用。随着深度学习的不断发展,人们对基于深度学习的关系抽取的兴趣也逐渐增加,试图使用神经网络自动学习语义特征。近期,大量领域关系抽取模型^[4-7]被提出,且陆续应用于生物医学关系抽取^[8]、KPI(Key Performance Indicators)关系抽取^[9]等多个领域。在这些领域关系抽取模型中,基于深度神经网络的模型在领域语义的探索和开发方面表现出了很好的性能。虽然上述基于深度神经网络的领域关系抽取模型已经取得了较好的效果,但它们仍然面临着以下挑战。

1) 实体语义表征不足。之前提到的关系抽取模型大多都是通过预训练模型得到实体语义,这个语义可以被认为是一个初级的版本。但是在领域关系抽取中,由于预训练模型通常在通用的大规模语料库中训练,经常会出现预训练的语料库中没有领域实体的情况,从而导致表示领域实体的特征不足,从而进一步影响到了识别关系类型的性能。但是,如果本文利用与实体相对应的图像语义进行补充,就可以更全面地丰富该领域实体的语义表示,进而提升关系分类的性能。这表明学习多视角语义对于领域关系抽取有一定帮助。

2) 如何最大化获取两个视角之间的相关信息。本文为了解决第一个问题,引入第二视角的内容,而如何融合两个视角的内容就成为了关键。之前的工作大多采用拼接的方法来实现语义融合,这样的做法虽然提高了性能,但也引入了和实体不相关的信息。为了进一步提高关系分类的性能,就需要获取两个视角之间最大化的相关信息。本文采用信息瓶颈的方法,把该问题表述为最小化信息损失函数。该函数旨在尽可能地压缩每个视角包含的信息,同时最大化保存两个视角之间的相关信息。

为了解决上述具有挑战性的问题,提出一种新颖有效的模型(Multi-View Information Bottleneck Relation Extraction, MIBRE)。大多数现有的领域关系分类模型往往没有考虑到图像视角对模型语义的补充。MIBRE 模型可以通过从多个相应的图像中自动提取语义信息,从而充分利用图像视角的语义来增强领域实体的表示。具体如下:为了更加充分地表

述语义信息,引入 VggNet 提取图片中的信息,并与相应的实体特征进行融合;之后,引入了异构图神经网络,该网络在相同的图结构空间中对单词和关系节点进行建模,以捕获上下文语义;为了最大化两个视角之间的互信息,同时降低模型中不相关或冗余信息对模型的影响,引入了信息瓶颈理论,对学习到的特征进行压缩与保存。通过增强领域实体的表示并获取两个视角之间最大的相关信息,可以保证安全风险识别能够达到令人满意的结果。在两个真实数据集上的实验表明,MIBRE 模型优于几个基准模型。

综上,本文方法利用图像信息来增强实体表示,并将关系节点和单词节点共同作为图网络的节点表示,利用异构图进行训练,最后使用信息瓶颈进行特征的压缩与保存。本文的主要贡献包括以下 3 方面:

1) 提出了一种新的方式来增强领域实体信息,旨在通过融合文本视角语义和图像视角语义,解决安全风险识别中由于实体信息不足产生的问题;

2) 通过扩展信息瓶颈理论,在安全风险关系识别中,设计了一种新的方法来获取两个视角间最大的相关信息,并且减少与当前任务无关的不相关信息;

3) 在两个真实领域数据集上的实验验证了所提模型的优越性和有效性。

2 相关工作

2.1 关系抽取

关系抽取(Relation Extraction, RE)是自然语言处理(Natural Language Processing, NLP)领域的一项基本任务,它分为 4 类:有监督关系抽取^[10]、半有监督关系抽取^[11]、无监督关系抽取^[12]和远程监督关系抽取^[13]。近年来,大多数研究人员专注于基于神经网络的监督关系抽取和远程监督关系抽取,这两种方法都取得了很好的效果。随着深度学习的广泛应用,基于深度学习的关系抽取已成为研究的热点。2012 年,Socher 等^[14]首先将 RNN 引入关系抽取任务,解决了传统方法无法高质量捕获长距离依赖关系的严重问题。同年,Zeng 等^[15]提出使用 CNN 进行关系抽取,并利用卷积神经网络提取输入句子的局部特征。这些模型都面临无法捕捉全局信息的问题。Sun 等^[16]为了解决长距离依赖问题,提出使用 PCNN 模型进行关系抽取,并根据实体位置对抽取的句子进行分片,在电力通信规划文本中取得了较大的提升。为了提高模型在长距离依赖问题上的能力,依存树也被应用于关系抽取中。Yan 等^[17]将依赖分析树特征与词向量特征和词性特征相结合,然后利用多个 LSTM 进行特征的提取,取得了较好的效果,但消耗了更多的计算资源。近年来,随着图神经网络的发展,越来越多的人开始利用图神经网络来研究关系抽取。Wu 等^[18]提出了一种基于可视化分析的、面向工程的基于 MLP 的 GNN 关系抽取模型,以深入理解 GNN 在关系抽取任务中的表现并提高效率。同样,也有很多模型利用额外信息增强关系抽取的效果,如知识图谱、图片信息等。Zhuang 等^[19]利用知识对事件本体进行提示增强,并在时间关系抽取中取得了不错的效果。

以上工作尽管在各个领域已经取得了不错的效果,推动

了关系抽取的进步与发展,但是均没有考虑到使用图片信息直接增强实体的特征,利用图片信息来补充实体信息将大大增加模型的表现力。

2.2 信息瓶颈

1999年,Tishby等^[20]为了实现信息压缩和噪声去除,提出了基于互信息的信息瓶颈理论。信息瓶颈(Information Bottleneck, IB)方法研究了压缩和预测之间的权衡:在从输入变量 X 中提取相关信息,同时保留另一个随机变量 Y 的相关信息后,得到的表示是另一个变量 Z 。这通过最小化以下因素来实现:

$$\min I(X;Z) - \beta I(Z;Y) \quad (1)$$

其中, $I(\cdot; \cdot)$ 表示两个随机变量之间的互信息, β 是权衡压缩和保存的参数。最近,在深度学习中使用信息瓶颈已经成为一个热点。Cui等^[21]通过多模态表征学习与信息瓶颈相结合的方式,解决了模态噪声和模态差距的问题。在自然语言处理的其他任务中,信息瓶颈方法主要用于表示学习, Li等^[22]使用变分信息瓶颈来非线性压缩 BERT 预训练的词嵌入。Amjad等^[23]采用信息瓶颈方法来研究基于神经网络的分类的表示。利用信息瓶颈来压缩信息已经成功应用于许多领域中,但很少有研究人员在关系抽取中使用信息瓶颈理论来进行冗余信息的压缩,导致模型在关系抽取任务中存在较多冗余信息,使得模型面临复杂场景时没有关注更加有意义的信息。

3 基于多视角 IB 的安全风险关系抽取模型

在大数据的背景下,为了解决传统方法的低效和不准确问题,本文使用深度神经网络来自动学习安全风险的关系特征。MIBRE 模型主要包括 4 个阶段,如图 1 所示。

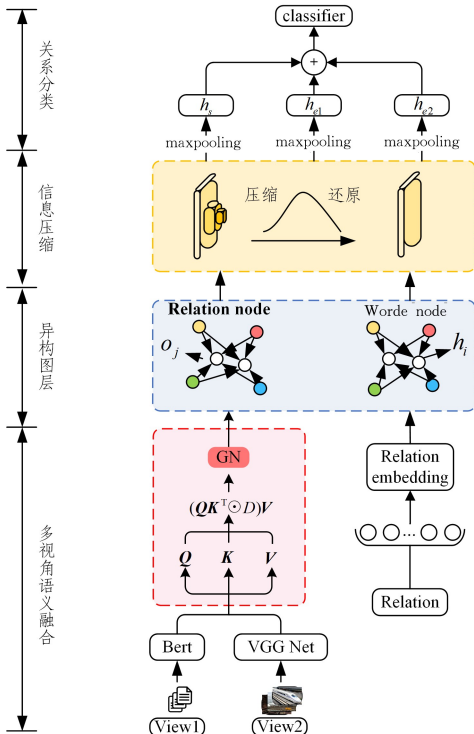


图 1 多视角 IB 安全风险关系抽取模型图

Fig. 1 Multi-view IB safety risk relation extraction model diagram

首先,将输入句子以及实体对应的图片进行编码,融合上

下文信息,并将关系节点进行编码;其次,通过异构图神经网络实现上下文语义和关系信息之间的融合,对不同类别的两种特征进行融合,提升模型预知关系的能力;再次,为解决传统领域关系抽取中实体表征不足的问题,引入多视角方法来增强领域实体表征,在融合两个视角语义信息的时候,采用信息瓶颈的方法获取两个视角间最大的相关信息,用于表示最终融合后的语义表示;最后,通过对获取到的最终编码执行 max-pooling 操作,获取到句子的表征以及两个实体的表征,并通过线性层进行分类。

3.1 问题定义

定义 1 给定多视角数据,设 $T = \{x_1, x_2, \dots, x_{|T|}\}$ (x_i 是一个字)为输入的句子,领域关系抽取的目的是识别实体对 (x_{sub}, x_{obj}) 的关系类型 r ,其中关系集为 $r \in R, x_{sub} \in T, x_{obj} \in T$ 。下面为一个数据集中的例子:“左侧<e1>沟</e1>排水设施未及及时清除杂草,<e2>积水</e2>严重”,该任务主要是预测实体 1“沟”和实体 2“积水”之间的关系类型。

3.2 语义融合与信息压缩

本节采用如图 1 所示的多视角语义融合策略进行编码,实现安全风险知识的抽取任务。首先,对于将分词后的安全风险,利用预训练语言模型 BERT 获得低维的词向量。具体来说,对于输入句子 T ,词 $x_i \in \mathbb{R}^d$ 表示为:

$$x_i = (x_i^w, x_i^l) \quad (2)$$

其中, $x_i^w \in \mathbb{R}^{d_w}$ (d_w 是词向量的维度), $x_i^l \in \mathbb{R}^{d_l}$ (d_l 是位置向量的维度)。

为了增强领域实体语义信息,采用融合图像视角语义信息的方法,该方法补充了预训练模型中不充分的表示。具体来说,对于领域实体 x_i ,本文匹配对应的图像集 $m = \{m_{i1}, m_{i2}, \dots, m_{im}\}$,之后使用 VggNet 来获得图像特征向量 m_i ,最后直接将图像特征向量与对应的实体特征 x_i 进行相加。

为了更加充分地融合两个视角之间的信息,使用 RetNet 来学习文本和图片之间的信息,从而利用图片之间存在的信息来补充文本中语义表示的不足。

在相同的异构图空间中对单词节点和关系节点进行建模,以捕获具有更多任务相关特征的丰富上下文语义。为了更好地理解异构图,将词 x_i 的表征重写为词节点 $\{h_i\}_{i=1}^{|T|}$,将关系 r_i 编码为关系节点 $\{o_i\}_{i=1}^{|R|}$ 。按照已有工作,引入了一种消息传递机制,它通过以下方式更新节点表示:

$$\begin{cases} a_{ij} = W_a [W_q h_i; W_k o_j] \\ a_{ij} = \frac{\exp(a_{ij})}{\sum_{l \in \mathcal{N}_i} \exp(a_{il})} \\ h_i' = h_i + \sum_{j \in \mathcal{N}_i} \alpha_{ij} W_v o_j \end{cases} \quad (3)$$

其中, $[\cdot; \cdot]$ 表示将两个向量连接成新表示, \mathcal{N}_i 表示第 i 个节点的相邻点, W_a, W_q, W_k, W_v 是可训练权重。然后使用门机制代替激活函数,这样可以保证每个维度的规模并且保持非线性能力,具体如下所示:

$$\begin{cases} v_i = \text{sigmoid}(W_g [h_i; h_i']) \\ \tilde{h}_i = v_i \odot h_i' + (1 - v_i) \odot h_i \end{cases} \quad (4)$$

其中, W_g 是可训练权重。为了方便起见,将异构图的上述操作总结为:

$$\tilde{\mathbf{h}}_i = \text{GNN}(\mathbf{h}_i, \{\mathbf{o}_j\}_{j \in \mathcal{N}_i}) \quad (5)$$

同理,可以得到关系节点的编码:

$$\tilde{\mathbf{o}}_i = \text{GNN}(\mathbf{o}_i, \{\mathbf{h}_j\}_{j \in \mathcal{N}_i}) \quad (6)$$

执行上述操作后,能够获取到一个具备多视角图片信息和关系信息的词表征,但是融合了多种表征的信息存在较多冗余信息,如图片背景噪声。利用信息瓶颈先压缩后还原的思想,对学习到的单词表示 $H = \{\tilde{\mathbf{h}}_i\}_{i=1}^{|T|}$ 执行下面的压缩与还原操作:

$$\begin{aligned} L_1 &= I(\mathbf{Y}; \mathbf{Z}) - \beta I(\mathbf{Z}; \mathbf{H}) \\ &= \int_{x,z} p(y,z) \log \frac{p(y,z)}{p(y)p(z)} - \beta \int_{z,h} p(z,h) \\ &\quad h) \log \frac{p(z,h)}{p(z)p(h)} \\ &= \int_{x,z} p(y,z) \log \frac{p(y|z)}{p(y)} - \beta \int_{z,h} p(z,h) \log \frac{p(z|h)}{p(z)} \\ &\geq \frac{1}{N} \sum_i \mathbb{E}_\epsilon [-\log \frac{p(y|z)}{q(z)} + \beta \text{KL}(p(y|z), q(z))] \quad (7) \end{aligned}$$

其中, \mathbf{Z} 表示压缩后的变量信息, \mathbf{Y} 表示需要预测的信息, ϵ 表示标准正态分布, N 表示训练示例的数量, $q(z)$ 表示 $p(z)$ 的变分估计, KL 表示 Kullback-Leibler 散度。

3.3 关系分类和目标函数

经过信息瓶颈的压缩后,获取到的特征包含较少的冗余信息以及噪声信息。为了将对应实体表示和句子表示通过固定大小的向量表示,利用 max-pooling 机制获取到相应实体的表示,并使用拼接操作将实体信息和句子信息拼接到一起,然后通过前馈神经网络来获取到关系分类的最终表示 \mathbf{O}_r 。最后,将获得的高级语义输入到 softmax 分类器中,计算实体所属的安全风险关系的条件概率 $p(r|T, \theta)$, 如下所示:

$$p(r|T, \theta) = \frac{\exp(\mathbf{O}_r)}{\sum_{i=1}^{|R|} \exp(\mathbf{O}_i)} \quad (8)$$

其中, $|R|$ 是安全风险关系类型的数量, \mathbf{O}_r 是异构图神经网络的最终输出,即所有安全风险关系类型的预测结果。最后使用交叉熵来进行分类,如下所示:

$$L_2 = \sum_{i=1}^n \log p(r_i | T_i, \theta) \quad (9)$$

其中, n 是输入句子集合的数量, θ 是本文模型需要学习的一组参数。模型的总损失为:

$$L = L_1 + L_2 \quad (10)$$

在模型的训练中,使用随机梯度下降算法 (SGD) 来优化目标函数。通过设计以上损失函数,可以达到以下目的:1) 获取到与任务最相关的特征;2) 根据真实标签学习特征。 L_1 的设计旨在学习数据中最重要的特征。找到一种最优的中间表示或编码 \mathbf{Z} , 这个表示应当尽可能保留从输入 \mathbf{X} 到目标变量 \mathbf{Y} 所需的有用信息,同时最大程度地去除输入中的冗余和不相关的信息,从而达到学习数据中最关键特征的目的。这个目标函数的优化使得模型能够学习到更加紧凑、有意义的表示,从而在处理数据时更有效地提取和利用信息。 L_2 设计的主要目标是衡量模型的预测与真实标签之间的差异,即模型输出的概率分布与真实标签的分布之间的距离。

4 实验验证及分析

4.1 数据集与评价指标

为了验证本文模型能够自动获取安全风险知识,在真实数据集 RVSR (Railway Vehicle Safety Risk) 和 RMSR (Railway Maintenance Safety Risk) 上进行实验,它们源自中国铁路局的安全监管系统。RVSR 数据集主要描述了安检员记录的铁路段不安全生产状况,包括 9285 个句子,其中有 4236 个关系实例。RMSR 数据集主要描述了安检员记录的铁路路段不安全生产情况,包括 26180 个句子,其中有 10487 个关系实例。

我们花了 3 个多月的时间来注释这些数据集,每个句子都由 3 名志愿者标记。共有 4 种安全风险关系,分别是:环境安全风险、公共工程设备的安全可靠性、人员操作安全和管理有效性。本文随机选择了 80% 的数据作为训练数据集,20% 的数据作为测试数据集。

根据之前的工作^[15-17],共采用 6 个经典的指标来评估关系抽取模型的性能,分别是 P@N (包括 P@100, P@200, P@300, P@Mean), AUC 以及 F1。

4.2 对比算法与实验设置

为了验证所提关系抽取模型的有效性,选择 LGGCN^[24], TDGAT^[25], BERT-GMAN^[26], PCNN + ATT^[27], PRM-CNN^[28], Ensemble BiLSTM^[29], SPCNN^[30], EMGCE^[31] 这 8 种模型进行比较。

为了探索图像中增强语义的有效性,从 {0, 1, 3, 5, 10} 中选择图像数量;超参数 β 的值从 {0.01, 0.001, 0.0001, 0.00001, 0.000001} 中选择;其他超参数的设置如表 1 所列。所有实验均在配备 Intel(R) Xeon(R) Silver 4216 CPU @ 2.10GHz、4 NVIDIA Tesla V100 GPU (每个 32 GB) 和 Ubuntu 14.04 操作系统的服务器上进行。

表 1 超参数的设置

Table 1 Hyperparameters setting

Hyperparameters	Values
Maximum number of words	150
Word vector dimension	768
Image vector dimension	4096
Batch size	8
Learning rate	0.00001
β	0.001

在研究中,针对特定领域的文本数据,使用预训练的 BERT 模型来提取实体之间的关系。首先,使用 PyTorch 加载和微调预训练的 BERT 模型,以适应本文任务的特定需求。接着,利用已标注的数据进行模型的训练,采用 SGD 优化器来最小化模型在训练集上的损失。在模型训练完成后,对测试集进行预测,并利用评估指标如准确率、AUC 和 F1 分数来评估模型的性能。通过这一过程,我们能够有效地从文本中提取出实体之间的关系。

对于基准方法的实验设置,基本的模型框架与本文方法类似,模型的设计与实现按照原文献提供的信息进行复现,在本文的数据集上进行实验验证。为了进行公平的实验对比,同样对基准模型进行参数调优,选择最好的实验结果进行比较。

4.3 实验结果与分析

本节将在两个真实数据集上验证所提模型的有效性,表2和表3中列出了两个数据集上所有模型的 P@N, AUC 和 F1。为了更直观地看出本文模型的优越性,图2和图3中展示了 RVSR 和 RMSR 上的精度召回曲线。

表2 不同方法在数据集 RVSR 上的性能

Table 2 Performance of different methods on RVSR dataset

Model	P@100	P@200	P@300	P@Mean	AUC	F1
LGGCN	63.42	62.21	62.25	62.63	51.38	59.87
TDGAT	63.23	65.40	64.78	64.47	52.55	62.38
BERT-GMAN	55.38	54.16	52.09	53.88	43.10	59.26
PCNN+ATT	62.51	60.38	62.15	61.68	45.61	58.01
PRM-CNN	52.81	51.61	51.33	51.92	43.84	58.34
Ensemble BiLSTM	36.64	45.30	47.67	43.20	43.68	57.91
SPCNN	55.83	56.12	53.34	55.10	47.84	58.34
EMGCE	50.32	50.53	47.28	49.38	46.53	59.15
MIBRE	66.53	69.81	66.05	67.46	54.16	64.28

表3 不同方法在数据集 RMSR 上的性能

Table 3 Performance of different methods on RMSR dataset

Model	P@100	P@200	P@300	P@Mean	AUC	F1
LGGCN	93.86	94.33	97.80	95.33	59.05	71.36
TDGAT	98.20	94.15	93.93	95.43	60.33	72.81
BERT-GMAN	95.51	94.62	93.19	94.44	57.34	69.21
PCNN+ATT	97.18	95.43	94.05	95.55	61.46	70.84
PRM-CNN	96.72	95.75	94.43	95.63	56.24	68.16
Ensemble BiLSTM	87.62	83.70	82.75	84.69	45.84	63.27
SPCNN	88.23	86.17	86.26	86.89	47.76	62.12
EMGCE	81.75	85.22	86.68	84.55	40.17	55.45
MIBRE	97.91	96.26	95.44	96.54	63.06	74.34

从表2和表3中可以看出:MIBRE模型在两个真实数据集上均明显优于对比的关系抽取模型。具体来说,LGGCN和TDGAT模型通常将输入的句子表示为一个图,旨在利用图神经网络捕获更多特征的信息,并没有解决领域实体表征不足的问题,关系抽取效果不明显。而本文模型由于利用图片信息补充了实体的信息,模型的效果得到了提升。相较于基于异构图的LGGCN模型,本文模型的F1值分别提升了4.41%,2.98%;相较于基于注意力机制的TDGAT模型,F1值分别提升了1.89%,1.53%。BERT-GMAN模型通常强调短语来捕获和任务相关的特征,但并没有给对关系抽取很重要的但表征不足的实体赋予突出的权重。对比本文模型和PCNN+ATT与SPCNN,由于中文实体长度的问题,分段PCNN+ATT并不能很好地解决关系抽取在中文中的问题。最后对比本文模型和PRM-CNN,Ensemble BiLSTM,以及EMGCE,它们均旨在提高语义信息的理解能力,而本文的模型采用了多视角的方法,融合了图像视角的语义,显著提高了领域实体的表示能力,同时也提高了理解上下文语义的性能。这一观察表明,本文引入图像视角有利于关系抽取。

从图2和图3中不难看出,本文方法在两个数据集上都取得了很好的效果。具体而言,模型MIBRE的PR曲线总体位于对比模型上方,这意味着在相同的召回率下,提出的模型具有更高的准确率。在铁路安全风险识别中,较高的准确率

可以减少安全问题的发生。

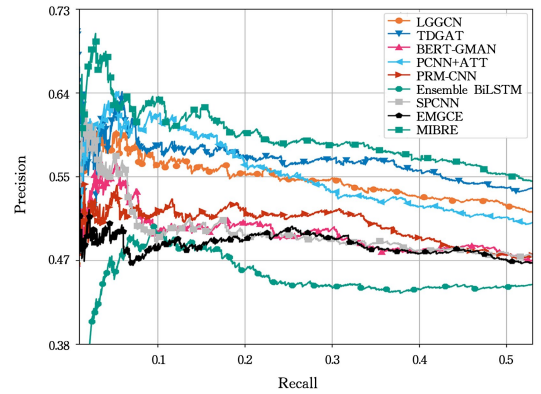


图2 在数据集 RVSR 上不同模型的精度召回曲线

Fig. 2 Precision-recall curves of different models on RVSR dataset

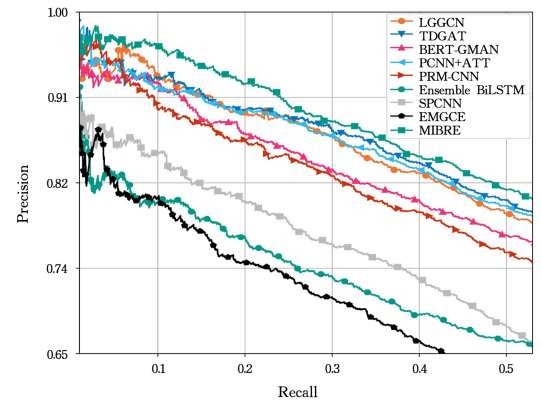


图3 在数据集 RMSR 上不同模型的精度召回曲线

Fig. 3 Precision-recall curves of different models on RMSR dataset

相对于其他方法,MIBRE模型的优势主要体现在以下两个方面:1)通过融合多视角语义信息,极大地增强了领域实体语义,解决了领域实体语义表征不足的问题,有助于提高关系抽取模型的性能;2)通过信息瓶颈方法获取视角间最大的相关信息,相比于之前简单地把各个视角的信息拼接在一起的方法,可以充分地利用视角内的信息,从而提高模型的关系抽取性能。综上所述,本文提出的方法增强了安全风险识别的有效性。

4.4 图片数量分析

之前的工作很少通过融合图像视角语义来增强实体表示,因此有必要讨论融合图像视角的语义是否真的有利于关系抽取。此外,本文更进一步地研究了不同数量图像对模型的影响。从{0,1,3,5,10}中选择图像数量,其中0表示没有嵌入图像语义,其余数字表示由每个领域实体对应的图像数量。

从表4和表5中可以看出:只要有一张图片,就可以提高领域关系抽取任务的性能,这验证了本文的假设,即融合图像视角的语义可以增强领域实体的表示。此外,在包含3张图片数量时,相比使用1张图片而言,在两个数据集上的F1分别增长了1.99%,1.53%。而当图像数量增长到5,10时,模型的效果开始逐步下降。原因在于,过多的图像数据往往伴随着更多的噪声,导致模型性能下降。

表 4 不同图片数量下 MIBRE 在数据集 RVSR 上的性能

Table 4 Performance of MIBRE with different numbers of images on RVSR dataset

	(%)					
Numbers	P@100	P@200	P@300	P@Mean	AUC	F1
N=0	66.58	65.23	65.15	65.65	51.85	62.03
N=1	68.33	67.18	63.21	66.24	53.34	62.29
N=3	66.53	69.81	66.05	67.46	54.16	64.28
N=5	63.17	65.29	65.88	64.78	52.03	61.42
N=10	64.13	63.91	61.39	63.13	50.11	59.86

表 5 不同图片数量下 MIBRE 在数据集 RMSR 上的性能

Table 5 Performance of MIBRE with different numbers of images on RMSR dataset

	(%)					
Numbers	P@100	P@200	P@300	P@Mean	AUC	F1
N=0	96.20	94.33	94.65	95.06	61.01	72.36
N=1	95.34	96.82	94.71	95.62	61.97	72.81
N=3	97.91	96.26	95.44	96.54	63.06	74.34
N=5	94.23	95.10	95.87	95.07	62.33	73.04
N=10	93.77	94.36	94.40	94.18	60.28	71.36

随着图像数量的增加(从 1 到 10),MIBRE 模型性能最初会增加,然后会降低。在这两个铁路数据集上,当图像数量大于 3 时,MIBRE 模型的性能开始逐步下降。这表明 3 幅图像已经能够增强模型的性能,相反,融合大量图像会引入意想不到的无关特征,然后引起模型性能的下降。综上所述,在引入少量图像后,模型的效果得到了提高,验证了使用多视角信息对安全风险识别的有效性。

结束语 本文针对在安全风险识别领域关系抽取中实体表征不足的问题,提出了一种基于多视角 IB 的关系抽取模型 MIBRE。该模型使用多视角语义来增强实体语义,并且通过信息瓶颈理论获取两个视角间最大的相关信息,从而提升模型的性能。在两个真实的铁路数据集上的实验结果表明,MIBRE 模型优于现有的关系抽取模型。但本文模型依然存在不足之处,在利用图神经网络优化不同类型节点时,执行两次图卷积操作,时间复杂度过高。在未来的工作中,将继续关注多视角数据的融合,继续探索如何利用新的类型视角数据,如音频、视频等信息。这是一项更大的挑战,同时也是人工智能未来研究的方向。

参 考 文 献

[1] SHANG B,ZHAO Y,LIU J. Learnable convolutional attention network for knowledge graph completion[J]. Knowledge-Based Systems,2024,285:111360.

[2] SOUSA R T,SILVA S,PESQUITA C. Explaining protein-protein interactions with knowledge graph-based semantic similarity [J]. Computers in Biology and Medicine,2024,170:108076.

[3] CHEN J,HU J,LI T,et al. An effective relation-first detection model for relational triple extraction[J]. Expert Systems with Applications,2024,238:122007.

[4] LAI T,JI H,ZHAI C,et al. Tran,Joint biomedical entity and relation extraction with knowledge-enhanced collective inference [C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics. 2021:6248-6260.

[5] CHEN J,HU B,PENG W,et al. Biomedical relation extraction via knowledge-enhanced reading comprehension[J]. BMC Bioinformatics,2022,23:20.

[6] PÉREZ-PÉREZ M,FERREIRA T,IGREJAS G,et al. A deep learning relation extraction approach to support a biomedical semi-automatic curation task: The case of the gluten bibliome [J]. Expert Systems with Applications,2022,195:116616.

[7] ROY S,PACHECO M,GOLDWASSER D. Identifying morality frames in political tweets using relational learning[C]// Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing. 2021:9939-9958.

[8] ZHAO D,WANG J,LIN H,et al. Biomedical cross-sentence relation extraction via multihead attention and graph convolutional networks[J]. Applied Soft Computing,2021,104:107230.

[9] HILLEBRAND L,DEUBER T,KHAMENEH T,et al. KPIBERT:A joint named entity recognition and relation extraction model for financial reports [C]//Proceedings of the 26th International Conference on Pattern Recognition(ICPR). 2022:606-612.

[10] ZENG D,LIU K,LAI S,et al. Relation classification via convolutional deep neural network[C]// Proceedings of the Conference 25th International Conference on Computational Linguistics. Dublin, Ireland,2014:2335-2344.

[11] YANG C,XIAO D,LUO Y,et al. A hybrid method based on semi-supervised learning for relation extraction in Chinese emrs [J]. BMC Medical Informatics Decis Mak,2022,22:169.

[12] WU R,YAO Y,HAN X,et al. Open relation extraction: Relational knowledge transfer from supervised data to unsupervised data[C]// Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing. 2019:219-228.

[13] MINTZ M,BILLS S,SNOW R,et al. Distant supervision for relation extraction without labeled data[C]// Proceedings of the 47th Annual Meeting of the Association for Computational Linguistics. Singapore,2009:1003-1011.

[14] SOCHER R,HUVAL B,MANNING C,et al. Semantic compositionality through recursive matrix-vector spaces[C]// Proceedings of the Joint Conference on Empirical Methods in Natural Language Processing & Computational Natural Language Learning. 2012:1201-1211.

[15] ZENG D,LIU K,LAI S,et al. Relation classification via convolutional deep neural network[C]// Proceedings of International Conference on Computational Linguistics. 2014:2335-2344.

[16] SUN H B,LI S X,TONG W Y,et al. Construction of Knowledge Graph of Power Communication Planning based on Deep Learning[C]// Proceedings of the 6th Information Technology and Mechatronics Engineering Conference. 2022:843-851.

[17] XU Y,MOU L,GE L,et al. Classifying relations via long short term memory networks along shortest dependency paths[C]// Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing. 2015:1785-1794.

[18] WU T,YOU X,XIAN X,et al. Towards deep understanding of graph convolutional networks for relation extraction [J]. Data & Knowledge Engineering,2024,149:102265.

[19] ZHUANG L,FEI H,HU P. Knowledge-enhanced event relation

- extraction via event ontology prompt[J]. *Information Fusion*, 2023,100:101919.
- [20] TISHBY N, PEREIRA F, BIALEK W. The information bottleneck method[C]// *Proceedings of the 37th Annual Allerton Conference on Communication Control Computing*. 1999:368-377.
- [21] CUI S, CAO J, CONG X, et al. Enhancing multimodal entity and relation extraction with variational information bottleneck[J]. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2024,32,1274-1285.
- [22] LI X, EISNER J. Specializing word embeddings(for parsing) by information bottleneck[C]// *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing*. 2019:2744-2754.
- [23] AMJAD R, GEIGER B. Learning representations for neural network-based classification using the information bottleneck principle[J]. *IEEE Trans. Pattern Anal. Mach. Intell.*, 2020, 42: 2225-2239.
- [24] HUANG W, MAO Y, YANG L, et al. Local-to-global GCN with knowledge-aware representation for distantly supervised relation extraction[J]. *Knowledge-Based Systems*, 2021,234:107565.
- [25] SUN Q, ZHANG K, HUANG K, et al. Document-level relation extraction with two-stage dynamic graph attention networks [J]. *Knowledge-Based Systems*, 2023,267:110428.
- [26] XU S, SUN S, ZHANG Z, et al. BERT gated multi-window attention network for relation extraction [J]. *Neurocomputing*, 2022,492:516-529.
- [27] LIN Y, SHEN S, LIU Z, et al. Neural relation extraction with selective attention over instances[C]// *Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics*(Volume 1: Long Papers). 2016:2124-2133.
- [28] ZHAO Q, GAO T, GUO N. A novel chinese relation extraction method using polysemy rethinking mechanism[J]. *Applied Intelligence*, 2023,53(7):7665-7676.
- [29] BUSST M M A, ANBANANTHEN K S M, KANNAN S, et al. Ensemble BiLSTM: A Novel Approach for Aspect Extraction From Online Text[J]. *IEEE Access*, 2024, 12: 3528-3539.
- [30] YU M, CHEN Y, ZHAO M, et al. Semantic piecewise convolutional neural network with adaptive negative training for distantly supervised relation extraction[J]. *Neurocomputing*, 2023, 537:12-21.
- [31] WU M, ZHANG Q, WU C, et al. End-to-end multi-granulation causality extraction model[J]. *Digital Communications and Networks*, 2023,10(6):1864-1873.



LI Xiwang, born in 1999, postgraduate. His main research interests include relation extraction and data mining.



SHE Wei, born in 1977, Ph.D, professor. His main research interests include complex system modeling and simulation, machine learning and intelligent systems, information security and blockchain technology.

(责任编辑:何杨)