

引用格式:张韬政,郭佳琪. 基于社交知识图谱的虚假新闻检测研究[J]. 中国传媒大学学报(自然科学版),2024,31(05):12-22.
文章编号:1673-4793(2024)05-0012-11

基于社交知识图谱的虚假新闻检测研究

张韬政*,郭佳琪

(中国传媒大学信息与通信工程学院,北京 100024)

摘要:社交知识图谱能够同时兼顾知识网络和社交信息,考虑到虚假新闻的传播特性以及其蕴含的知识信息,本文利用图神经网络和翻译模型构建了面向虚假新闻检测的社交知识图谱。首先,本文分别构建了社交图谱和知识图谱,通过对图谱进行特征提取等工作实现了对虚假新闻的检测;其次,本文利用实体对齐技术将构建好的社交图谱和知识图谱进行融合,完成了社交知识图谱的构建及后续的虚假新闻检测工作;然后,将本文提出的模型与基线模型进行虚假新闻检测实验的对比,证明了本文构建的基于社交知识图谱的虚假新闻检测模型能够有效地实现对虚假新闻的检测;最后,本文还通过Neo4j对示例新闻进行了图谱的可视化展示。

关键词:虚假新闻检测;图神经网络;社交图谱;知识图谱;社交知识图谱

中图分类号:TP391.1 **文献标识码:**A

Research on fake news detection based on social knowledge graph

ZHANG Taozheng*, GUO Jiaqi

(School of Information and Communication Engineering, Communication University of China,
Beijing 100024, China)

Abstract: Social knowledge graph can take into account both knowledge network and social information. Considering the propagation characteristics and the knowledge information of fake news, in this paper a social knowledge graph for fake news detection was constructed by using graph neural network and translation model. Firstly, the social graph and the knowledge graph were constructed respectively. The detection of fake news was realized through the feature extraction of the graph. Secondly, entity alignment to integrate the constructed graph was used. The construction of social knowledge graph and the detection of fake news were completed. Then, the detection results of fake news with this paper's model and baseline model were compared. It is proved that the fake news detection model based on social knowledge graph can effectively detect fake news. Finally, Neo4j was also used to visualize the graph of the sample news.

Keywords: fake news detection; graph neural network; social graph; knowledge graph; social knowledge graph

1 引言

虚假新闻的出现由来已久,但随着互联网的不断发展以及网络中用户数量的不断增加,虚假新闻传播

所造成的负面影响已经到了令人难以忽略的地步^[1]。为了尽可能解决虚假新闻所带来的负面影响,众多学者投身虚假新闻检测任务,力图找到更好的方法识别虚假新闻、遏制虚假新闻的大范围传播。

基金项目:国家重点研发计划项目(2023YFF0904604);中国传媒大学中央高校基本科研业务费专项资金资助(CUC23ZDTJ014)

作者简介(*为通讯作者):张韬政(1982-),女,博士,副教授,主要从事机器学习、自然语言处理研究。Email: zhangtaozheng@cuc.edu.cn;郭佳琪(1999-),女,硕士研究生,主要从事机器学习、自然语言处理研究。Email: gjq6433@163.com

对虚假新闻检测任务的研究经历了人工检测、传统机器学习检测、深度学习检测等多个阶段。早期的虚假新闻检测任务主要依靠人工识别,在这一过程中,不仅需要专业人员对虚假新闻进行定义、识别,还需要众多人工参与到虚假新闻的事件调查、背景调查等过程中。单纯通过人工识别进行虚假新闻判定虽然在一定程度上确保了识别结果的准确性,但却要浪费大量的人力物力,且判定虚假新闻的速度也极其缓慢。随着机器学习的兴起,虚假新闻检测任务逐渐从单纯的人工识别过渡到了机器识别^[2]。传统的机器识别方法包括支持向量机、随机森林、决策树等。这些方法在当时也大多取得了不错的效果,而且在很大程度上减少了人力的参与,但随着虚假新闻数量的不断增长,传统的机器学习方法已经不再能适应大规模数据所带来的计算压力,因此深度学习逐渐应用到了虚假新闻检测领域中。学者们利用神经网络模型对新闻的文本、图片、视频等多个模态进行研究,取得了不错的检测效果。近年来,图谱的概念逐渐兴起,知识图谱、兴趣图谱、社交图谱等概念频频在多个研究领域进行应用,虚假新闻检测领域也加大了对图谱的关注。学者们通过 TransE 模型、Neo4j 工具等开始了对知识图谱的大量研究,并且也在虚假新闻检测任务中取得了不错的效果。

Nguyen 等人^[3]认为新闻传播的社会语境可以被表示为一个异构网络,其中节点和边缘分别代表社会实体及其相互作用。该文献提出了一种新的图形化社会语境表示和虚假新闻检测学习框架——事实新闻图(FANG, factual news graph)。在对虚假新闻检测目标进行优化的同时,FANG 还会通过优化三个并发损失来学习社会实体的一般化表示。FANG 在训练中具有可扩展性,因为它不需要维护所有节点,并且在推理时效率很高,不需要重新处理整个图。

徐凡等人^[4]利用图神经网络进行虚假新闻检测研究,并将知识图谱的概念融入到了实验当中。该文献首先将新闻文本表示成一种语义-实体无向图,其中

节点包含原新闻文本中的词语以及扩展的实体词语和语义词语,边包含三类节点的6种有效组合。该语义-实体图可以有效地增强任意两种节点的共现性,从而丰富了原社交媒体文本的表示,从一定程度上缓解了数据稀疏共现问题。

除此之外,陈开阳^[5]提出了融合知识图谱的多模态虚假新闻检测;Hu 等人^[6]将待检测新闻与外部知识库中信息进行比较,从而判断新闻的真实性;Lao 等人^[7]提出融入世界知识图谱的路径排序算法(path ranking algorithm)下的虚假新闻检测模型。这些算法和模型为虚假新闻检测领域提供了更多的可能,推动着虚假新闻检测任务不断进步。

2017年,Yang 等人^[8]提出了社交知识图谱(social knowledge graph)的概念,旨在实现社交交互信息与通用知识的背景信息互补,随后有关社交知识图谱的研究也日渐增多。本文在前人研究的基础上,综合考虑新闻的社交信息和知识信息,将社交知识图谱应用到了虚假新闻检测任务中。

2 相关技术

2.1 图神经网络

早期的神经网络模型很难对非欧氏空间数据进行处理,然而在日常生活中,很多数据都是以非欧氏空间的形式呈现的。为了解决非欧氏空间数据的问题,学者们借鉴了卷积网络、循环网络和深度自动编码器的思想^[9],研究并设计了图神经网络。

图神经网络的基础目的就是利用神经网络实现对图结构数据的处理及应用,在此目的下,由于应用方向、实现方法等不同而衍生出了各种不同类型的图神经网络。

图卷积网络的原理和卷积神经网络密切相关,可以看作是卷积运算从传统数据向图结构数据的推广^[10]。图卷积网络的基本原理图如图1所示,即由输入图的节点特征向量和结构特征计算后生成针对该输入图的节点级输出。




图1 图卷积网络基本原理图

图注意力网络可以看作是注意力机制在图神经网络中的应用^[11]。图注意力网络计算公式可以简单表示为式(1)。

$$x'_i = \varepsilon_i \mathbf{W}x_i + \sum_{j \in N(i)} \varepsilon_{ij} \mathbf{W}x_j \quad (1)$$

其中, x 代表节点的特征向量, $N(i)$ 代表与节点 i 相邻的所有节点组成的域, \mathbf{W} 为权重矩阵, ε_{ij} 表示节点 j 对节点 i 的注意力,其计算公式为式(2)。

$$\varepsilon_{ij} = \frac{\exp(\text{LeakyReLU}(a^T [\mathbf{W}x_i \parallel \mathbf{W}x_j]))}{\sum_{k \in N(i) \cup \{i\}} \exp(\text{LeakyReLU}(a^T [\mathbf{W}x_i \parallel \mathbf{W}x_k]))} \quad (2)$$

其中,LeakyReLU为非线性激活函数, \parallel 表示将左右两个矩阵连接在一起, a 为权重向量。

图注意力网络的原理如图2所示,即通过softmax函数对特征向量进行归一化处理。

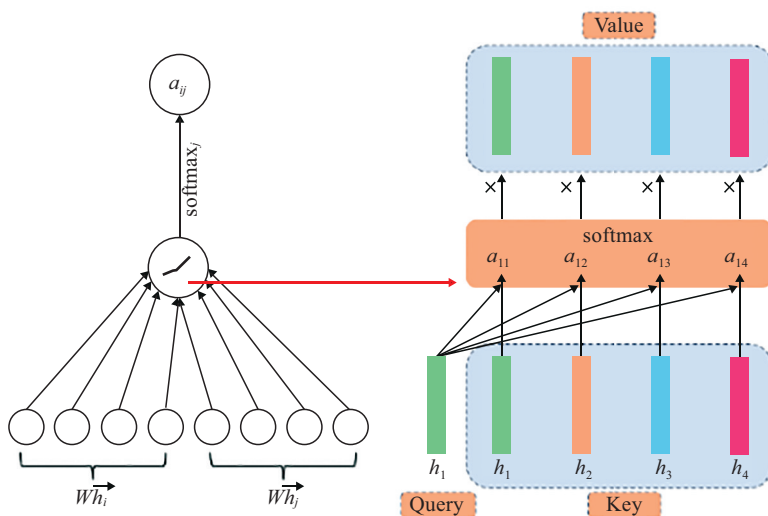


图2 图注意力网络原理图

除上述步骤外,还需对注意力系数进行进一步计算,具体计算公式如式(3)和式(4)所示。

$$z_i^{(l)} = \mathbf{W}^{(l)} x_i^{(l)} \quad (3)$$

$$x_i^{(l+1)} = \sigma \left(\sum_{j \in N(i)} a_{ij}^{(l)} z_j^{(l)} \right) \quad (4)$$

其中, l 代表神经网络第 l 层, z 为节点的特征向量与权重矩阵相乘后的结果。

和其他神经网络相同,图注意力网络也可以使用多头注意力机制,其运算公式如式(5)所示。

$$h_i = \parallel_{k=1}^K \sigma \left(\sum_{j \in N_i} \alpha_k(h_i^{t-1}, h_j^{t-1}) \mathbf{W}_k^{t-1} h_j^{t-1} \right) \quad (5)$$

其中, k 表示 k 重注意力机制, σ 是一个非线性函

数, h 表示多头注意力机制中的节点特征, $\alpha(\cdot)$ 是一个注意力函数,它自适应地控制相邻节点 j 对节点 i 的贡献。

2.2 实体对齐

实体对齐是进行图谱融合的重要方法,也有学者认为实体对齐本质上就是图谱融合^[12]。在常见的实体对齐任务中,基本技术流程如图3所示,即将预处理后的数据分块,通过负载均衡将分块后的结果进行调整,尽可能使每一块中的实体数目相差最少,然后记录连接、评估结果,最后将结果输出。




图3 实体对齐基本技术流程图

实体对齐的目的在于将不同图谱中对于同一实体的描述进行互补融合,使其更加全面、准确。如果

多个实体描述所对应的是同一个对象,则需要构建对齐关系,并对相关信息进行融合以及聚集^[13]。

本文中使用的实体对齐模型主要为TransE模型,相关模型及计算原理将在后文中介绍,此处只介绍GCN-Align模型。

GCN-Align^[14]是第一个利用图神经网络进行实体

对齐的模型,其模型示意图如图4所示,即通过图卷积网络将两个图谱嵌入到同一个向量空间,事先定义好距离函数作为量度,再通过计算实体间的距离实现对齐。




图4 GCN-Align模型示意图

GCN-Align模型的评分函数如式(6)所示。

$$E(e_1, e_2) = \beta \frac{f(H_s(e_1), H_s(e_2))}{d_s} + (1 - \beta) \frac{f(H_a(e_1), H_a(e_2))}{d_a} \quad (6)$$

其中, E 代表评分函数, $f(\cdot)$ 代表非线性函数, H_s 代表实体的结构嵌入, H_a 代表实体的属性嵌入, d_s 代表结构嵌入的维度, d_a 代表属性嵌入的维度, e 代表图谱中的实体, β 是超参数,用于衡量结构嵌入和属性嵌入的重要性。

3 社交知识图谱模型构建

在现有虚假新闻检测任务中,利用图谱已经成为了很常见的方式。学者们基于知识图谱或社交

图谱进行虚假新闻检测,已经取得了一定的成果。然而在现有的研究中,还存在着一些不足之处,如忽略了传播过程中树结构之外的带有环结构的拓扑结构,忽略了新闻文本本身可能存在的知识关系,忽略了知识关系与传播关系的内在联系等等。本文综合考虑新闻的社交信息和知识信息,构建了社交知识图谱并应用到虚假新闻检测任务中。本文首先分别构建社交图谱和知识图谱,再利用实体对齐将两个图谱进行融合构建社交知识图谱,最终实现了基于社交知识图谱的虚假新闻检测。基于社交知识图谱的虚假新闻检测模型如图5所示,即分别构建社交图谱和知识图谱,再通过实体对齐将两个图谱进行融合,实现基于社交知识图谱的虚假新闻检测模型的构建。

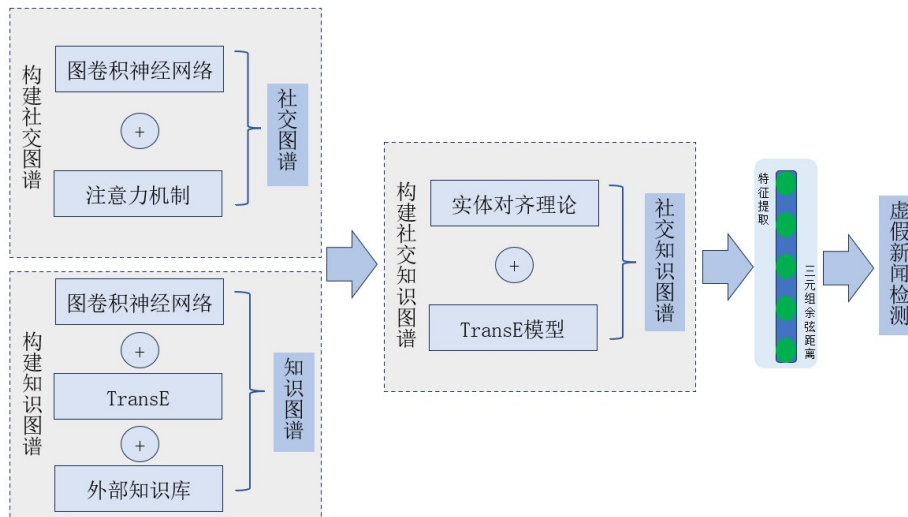


图5 基于社交知识图谱的虚假新闻检测模型

3.1 社交图谱

社交图谱构建部分引入了多关系图神经网络和注意力机制,将单一的树结构扩展为多方向、多关系、带有环结构的社交图谱。社交图谱示意图如图6所示。




图6 社交图谱示意图

图神经网络是较为常用的构建图谱的模型,然而传统的图神经网络主要应用于同质图,同质图的节点类型和节点关系都只有一种,这对于如今的知识结构显然已远远不够。为了应对这种情况,学者们研究了

多关系图神经网络^[5],专门应用于有多种节点类型和多种节点关系的异质图结构。多关系图神经网络在计算过程中引入了关系矩阵 W_r ,这使得其能够在图卷积网络的基础上增加对图结构中节点间的多种关系以及方向的关注。如果仅考虑隐藏层之间的传递,则关系图卷积网络的计算公式可表示为式(7)。

$$\begin{cases} H^{l+1} = f(\hat{A}H^lW_r^l) \\ H^0 = X \end{cases} \quad (7)$$

其中, H 代表图神经网络中的隐藏层, $f(\cdot)$ 是非线性函数, \hat{A} 是由邻接矩阵 A 和单位矩阵 I 组成的矩阵, X 代表初始输入。

有了关系图卷积网络,就能够基本实现在虚假新闻传播过程中对社交网络的图结构的获取与建模,这也就是社交图谱的雏形。

在虚假新闻传播的过程当中,不同的传播者对于虚假新闻传播的影响程度是不同的。因此在社交图谱构建过程中可以通过注意力机制对不同节点的重要性进行区分。

3.2 知识图谱

知识图谱是由各种知识及其之间的关系所构成的网络,其示意图如图7所示。

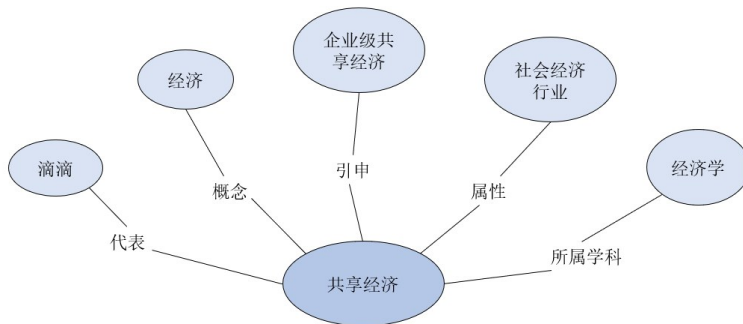


图7 知识图谱示意图

知识图谱的完整构建过程可简要概括为数据获取、实体关系抽取及实体关系嵌入三个部分,其中最重要的是实体关系抽取。本文采用的是基于图卷积网络的联合抽取模型。其示意图如图8所示,即通过图卷积网络分别进行实体特征提取和关系特征提取,再将提取到的结果进行计算,实现实体关系抽取。

本文的实体关系嵌入采用TransE模型。知识图谱通常由三元组表示,TransE模型认为,一个正确的三元组应该满足 $t = h + r$ 这个基本关系,若不满足,则认为该三元组是错误的。上述关系中 t 代表尾实




图8 实体关系抽取模型图

体, h 代表头实体, r 代表实体间的关系。TransE模型中三元组关系示意图如图9所示。




图9 TransE模型原理图

TransE模型的目标函数公式如式(8)所示。

$$E = \min \sum_{(h,r,t) \in G} \sum_{(h',r',t') \in G'} [\gamma + \text{distance}(h+r,t) - \text{distance}(h'+r',t')]_+ \quad (8)$$

其中, (h,r,t) 表示正确的三元组; (h',r',t') 表示错误的三元组; γ 表示正样本和负样本之间的距离, 是一个常数; $[x]_+$ 表示 $\max(0,x)$; $\text{distance}()$ 函数用于计算输入值的距离, 通常使用 L1 距离或 L2 距离。TransE 模型的目标就是让正例的距离最小, 也就是 $\min(\text{distance}(h+r,t))$, 让负例的相反数最小也就是 $\min(-\text{distance}(h'+r',t'))$, 对于每一个正样本和负样本求和, 再增加一个常数的间距, 就是整体距离的最小值。

本文构建知识图谱的数据获取来自于两部分, 一是虚假新闻数据集 Weibo、Twitter 等, 二是现有知识库 HowNet 以及 WordNet。HowNet 是一个以汉语和英语的词语所代表的概念为描述对象的知识库, WordNet 是一种基于认知语言学的英语词典。HowNet 和 WordNet 都是较为常用的知识库, 其中 HowNet 中包含中英文两种语言, WordNet 则只包含英文。WordNet 重视同义词之间的关联, 但关系方面不足以支持推理, 而 HowNet 可以在一定程度上弥补 WordNet 的这一点不足, 因此在实验中同时使用这两个外部知识库能够更有效地进行虚假新闻检测任务的实验。

3.3 社交知识图谱

社交知识图谱的主要思想就是将社交网络更好地融入到知识图谱当中。2023年2月, 江旭辉等人^[16]在其综述中给出了社交知识图谱的形式化定义, 即 $G = \langle V, E, P, R, I, T \rangle$, 其中 V 代表图谱中的节点, E 代表图谱中的边, P 代表节点的类型, 包括人员节点和其他节点, R 代表边的稳态关系, I 代表边的瞬态交互, T 代表边的时间范围集合。

社交知识图谱利用实体对齐技术将构建好的社

交图谱和知识图谱进行图谱融合。在本文实验中, 图谱皆以三元组的形式进行存储, TransE 模型能够有效的对三元组数据进行处理, 故本文选用了 TransE 模型进行图谱融合。由于本文前期构建的图谱并不是经过众多学者验证的公开图谱数据集, 因此在可能对齐的实体选择上范围有限, 在具体实验过程中, 本文主要考虑将在新闻传播过程中参与的“用户”作为两个图谱融合的关键实体进行社交知识图谱的构建。

除此之外, 本文还利用 Neo4j 工具对图谱进行了可视化展示。Neo4j 通过网页进行操作, 在网页中可以使用 Cypher 语言进行代码编写, 控制节点及关系的生成。在 Neo4j 网页中, 其结果以图、表等多种形式进行展示, 可以根据需要选择不同的结果展示方式。除了通过命令行操作之外, Neo4j 也支持数据文件的上传, 并根据上传文件生成相关图谱。

3.4 三元组余弦距离

虚假新闻检测的目标是通过模型判断出新闻是否真实, 因此其本质可以看作是一个二分类模型。本文选用三元组的余弦距离作为虚假新闻检测任务的分类器。

将真实新闻定义为 M , 对应的三元组为 (h,r,t) , 虚假新闻定义为 M' , 对应三元组为 (h',r',t') , 每个 M 中的三元组用下角标 i 表示, 计算原理如式(9)、式(10)所示。

$$f(M) = \frac{1}{|TS|} \sum_{i=1}^n \frac{h_i h_i + r_i r_i + t_i t_i}{\sqrt{h_i^2 + r_i^2 + t_i^2} * \sqrt{h_i^2 + r_i^2 + t_i^2}} \quad (9)$$

$$f(M') = \frac{1}{|TS|} \sum_{i=1}^n \frac{h'_i h'_i + r'_i r'_i + t'_i t'_i}{\sqrt{h_i'^2 + r_i'^2 + t_i'^2} * \sqrt{h_i'^2 + r_i'^2 + t_i'^2}} \quad (10)$$

其中, TS 表示真实新闻中提取的所有三元组, (h_i, r_i, t_i) 表示待判断的新闻提取的三元组。通过计算训练后的三元组和待判断三元组之间的余弦距离就可以判定新闻的真实性, 具体计算公式如(11)所示。

$$f(N) = \begin{cases} 0, & \text{if } f(M) > f(M') \\ 1, & \text{otherwise} \end{cases} \quad (11)$$

当 $f(N) = 1$ 时新闻为假, 当 $f(N) = 0$ 时新闻为真。

4 实验结果分析

4.1 实验数据集及评测指标介绍

本文所用数据集为 Weibo 数据集、Twitter 数据集以及 PHEME 数据集。Weibo 数据集来自于 Ma 等

人^[17]抓取的微博虚假新闻检测公开数据集;Twitter数据集包括Twitter15以及Twitter16,两个数据集都来自Ma等人在Twitter平台抓取的新闻数据^[18];PHEME^[19]数据集基于Twitter平台,其中包含了5个不同的事件以及相关的事件传播结构。数据集详情如表1所示。

表1 虚假新闻检测数据集

数据集名称	Weibo	Twitter15	Twitter16	PHEME
真实新闻	2351条	374条	205条	1067条
虚假新闻	2313条	370条	205条	638条
传播结构	4664个	1490个	818个	2402个

除虚假新闻检测实验外,本文还进行了针对图谱融合的实体对齐实验,选用的数据集为DBP15K和LinkedGeoData(LGD)数据集。这两个数据集都是实体对齐任务中较为常见的数据集,其中主要包含的信息为实体、关系、属性、三元组等。DBP15K数据集是DBP数据集的子集,其中包含了中文-英语、日语-英语以及法语-英语三种跨语言图谱,由于本节实验中跨语言的实体对齐并不是重点研究内容,因此仅选择了DBP15K数据集中中文-英语这一个类别用作实验数据。

LGD数据集是专门面向地理知识的数据集,其中的地理名词和DBP15K数据集链接,因此这两个数据集之间存在可以融合的可能性,同时两个数据集也可以分开单独进行实体对齐任务研究,故在本文实验中额外引入这两个数据集。具体的数据集信息如表2所示。

表2 实体对齐数据集

数据集	实体	关系三元组	属性三元组
DBP15K	中	66469个	153929个
	英	98125个	237674个
LGD	英	24309个	90054个

本实验使用的编程语言为Python3,深度学习框架为Pytorch,使用带有GPU的计算机进行实验。表3给出了实验涉及的模型共有的超参数及取值。

表3 本文实验中使用的超参数及取值

超参数名称	取值
Dropout	0.5
Optimizer	Adam
Batch	64个
Max_length	120字
Learning Rate	0.0005

本文在虚假新闻检测任务中使用的评测指标是

常用的准确率(Accuracy)、精确率(Precision)、召回率(Recall),以及F1值。在实体对齐实验中使用的评测指标是Hits@k以及MRR,接下来对Hits@k及MRR做一个简单的介绍。

Hits@k是指在前k个结果中存在正确实体的情况所占的比例,其计算公式如式(12)所示。

$$\text{Hits@k} = \frac{1}{|S|} \sum_{i=1}^{|S|} \varphi(\text{rank}_i \leq k) \quad (12)$$

其中, S 是三元组的集合, $|S|$ 是三元组集合的个数; $\varphi(\cdot)$ 是指示函数,其只能有0和1两个取值,当条件为真时,函数值取1,反之则取0; rank_i 是第*i*个三元组的链接预测排名。

MRR(mean reciprocal ranking)是排名的倒数的平均值,即所有正确对齐的实体的链接预测排名的倒数的平均值,其计算公式如式(13)所示。

$$\text{MRR} = \frac{1}{|S|} \sum_{i=1}^{|S|} \frac{1}{\text{rank}_i} \quad (13)$$

MRR的值越大,正确预测的排名数越小,实验效果也就更好,因此MRR越大越好。

4.2 实验结果及分析

本小节将对实验结果进行详细的介绍与分析,包括虚假新闻检测实验结果、对比实验结果以及图谱可视化实验结果。

4.2.1 虚假新闻检测实验

表4给出了虚假新闻检测的实验结果,其中实验内容列加粗部分是基于社交知识图谱进行虚假新闻检测的实验结果。为了证明本模型的有效性,本文分别基于社交图谱和知识图谱构建了虚假新闻检测模型并进行了实验,其具体结果如表中实验内容列未加粗部分所示。

表4 虚假新闻检测实验结果对比

数据集	实验内容	Accuracy	Precision	Recall	F1
Weibo	社交图谱	83.7%	83.5%	82.3%	82.9%
	知识图谱	80.9%	81.2%	81.0%	81.1%
	社交知识图谱	84.9%	84.3%	82.8%	83.5%
Twitter15	社交图谱	83.5%	83.1%	82.9%	83.0%
	知识图谱	81.0%	80.5%	81.3%	80.9%
	社交知识图谱	83.7%	84.1%	84.0%	84.0%
Twitter16	社交图谱	83.9%	82.9%	83.7%	83.3%
	知识图谱	81.4%	80.9%	80.8%	80.8%
	社交知识图谱	84.0%	83.1%	83.5%	83.3%
PHEME	社交图谱	82.8%	82.1%	83.0%	82.5%
	知识图谱	80.3%	80.0%	81.1%	80.5%
	社交知识图谱	83.5%	84.1%	83.4%	83.7%

由表4结果可知,构建社交知识图谱来进行虚假新闻检测实验能够有效地提高虚假新闻检测准确率及F1值,根据实验结果来看,实验准确率和F1值能够提高0.1%-4.1%左右。在现有研究中,基于社交图谱的虚假新闻检测侧重于传播路径,基于知识图谱的虚假新闻检测侧重于外部知识,而本文的社交知识图谱能够同时将传播路径和外部知识兼顾,因此在实验中的整体效果要优于对比模型。

4.2.2 对比实验

在对比实验部分,本文分别针对实体对齐和虚假新闻检测进行了实验,下文将对这两部分内容进行简单的介绍。

1) 实体对齐对比实验

本文在图谱融合实验中选用的TransE模型较为传统,为了证明TransE模型在实体对齐任务中的有效性,本文针对实体对齐任务进行了对比实验。相关数据集及评测指标在前文中已经有过介绍,由于实体对齐不是本文的研究重点,因此仅选择了MTransE和AttrGNN两个基线模型用于与本实验模型进行对比。

MTransE Muhao C等人^[20]提出的跨语言知识图谱融合模型。MTransE既提供了跨语言转换的功能,也保留了单语嵌入的功能。

AttrGNN Zhiyuan L等人^[21]提出的应用图神经网络进行基于属性三元组的实体对齐模型。

DBP15K数据集上的实验结果如表5所示,LGD数据集上的实验结果如表6所示。

表5 DBP15K数据集实验结果

模型	Hist@10	MMR
MTransE	58.3%	34.7%
AttrGNN	73.2%	69.4%
TransE	70.8%	57.3%

表6 LGD数据集实验结果

模型	Hist@10	MMR
MTransE	61.3%	38.5%
AttrGNN	74.2%	70.1%
TransE	70.9%	62.9%

由表可知,TransE模型在本文的图谱融合任务中能够起到一定的效果。从实验结果来看,TransE模型的实验效果稍好于MTransE模型,稍逊于AttrGNN模型。虽然从评测指标来看,本文选取的TransE模型不如AttrGNN模型,但评测指标数值相差也均在10%以

内。在实验过程中,AttrGNN模型训练时所花费的时间要远远长于TransE模型,考虑到时间和精力有限且本文的主要研究内容是虚假新闻检测任务,因此最终还是选择了用TransE模型进行社交知识图谱的构建。

2) 虚假新闻检测对比实验

为了进一步证明本文虚假新闻检测模型的有效性,选取了四个基线模型进行了针对虚假新闻检测任务的对比实验。

BtLSTM 郭亚杰等人^[22]融合了BERT模型以及LSTM模型,首先通过BERT层提取新闻的语义表示,再利用LSTM层进行特征提取,进而实现虚假新闻检测。

AGAT Chen L等人^[23]提出的将立场检测和谣言监测进行综合考虑的模型,该模型使用了多层图神经网络来同时完成立场检测和谣言检测,具有良好的谣言检测性能。

SEU^[24]该基线模型主要修改了实体对齐部分所使用的模型,通过Hungarian算法或者Sinkhorn算法实现实体对齐,从而构建社交知识图谱,进行虚假新闻检测。

GCN-Align^[14]该基线模型主要修改了实体对齐部分所使用的模型,通过图神经网络实现实体对齐,从而构建社交知识图谱,进行虚假新闻检测。

表7至表10给出的是不同数据集下对比实验的结果。

表7 Weibo数据集实验结果

实验模型	Accuracy	F1
BtLSTM	79.2%	80.1%
AGAT	83.2%	84.7%
SEU	80.4%	79.3%
GCN-Align	83.5%	82.8%
社交知识图谱	84.9%	83.5%

表8 Twitter15数据集实验结果

实验模型	Accuracy	F1
BtLSTM	80.2%	79.3%
AGAT	81.5%	81.3%
SEU	83.2%	81.7%
GCN-Align	82.9%	82.1%
社交知识图谱	83.7%	84.0%

表9 Twitter16数据集实验结果

实验模型	Accuracy	F1
BtLSTM	82.3%	81.4%
AGAT	83.2%	82.7%
SEU	79.9%	79.7%
GCN-Align	80.9%	81.5%
社交知识图谱	84.0%	83.3%

表 10 PHEME数据集实验结果

实验模型	Accuracy	F1
BiLSTM	79.2%	78.9%
AGAT	80.1%	79.9%
SEU	82.7%	81.9%
GCN-Align	83.2%	83.7%
社交知识图谱	83.5%	83.7%

从实验结果来看,本节所使用的模型能够有效地进行虚假新闻检测,与基线模型相比,准确率和F1值整体也有0.7%-5.7%左右的提升。在实验初期,对实体对齐部分的模型选择进行了提前测试,使用新闻数量在100条左右的自制数据集进行实验时,SEU模型的实验结果要优于TransE模型,TransE模型的实验结果优于GCN-Align模型。考虑到在实际实验过程中所使用的数据集规模要大于自制数据集,传统机器学习模型的计算性能稍差于TransE模型,因此在这二者之间选择了TransE模

型。而GCN-Align模型使用的是图神经网络,图神经网络是目前多数学者乐于尝试的模型,其效果也十分卓越,但在本文实验中该模型并未表现出足够优越的性能,考虑主要有两个原因:一是因为本文所选用的图神经网络模型相对较为早期,其模型性能还能有进一步的提高;二是因为本文后续进行虚假新闻检测的分类器使用的是余弦距离作为分类函数,可能与图神经网络的参数稍有差异。通过前期的测试以及后期的对比实验,都证明了TransE模型在本文实验环境下有整体较好的性能。

4.2.3 图谱可视化实验

为更直观地对本文构建的社交知识图谱进行展示,本文通过Neo4j分别构建了单一新闻的社交图谱、知识图谱以及社交知识图谱。示例新闻的相关信息来自于新浪微博,额外引入了百度百科相关词条用于补充知识图谱。Neo4j的操作界面如图10所示。

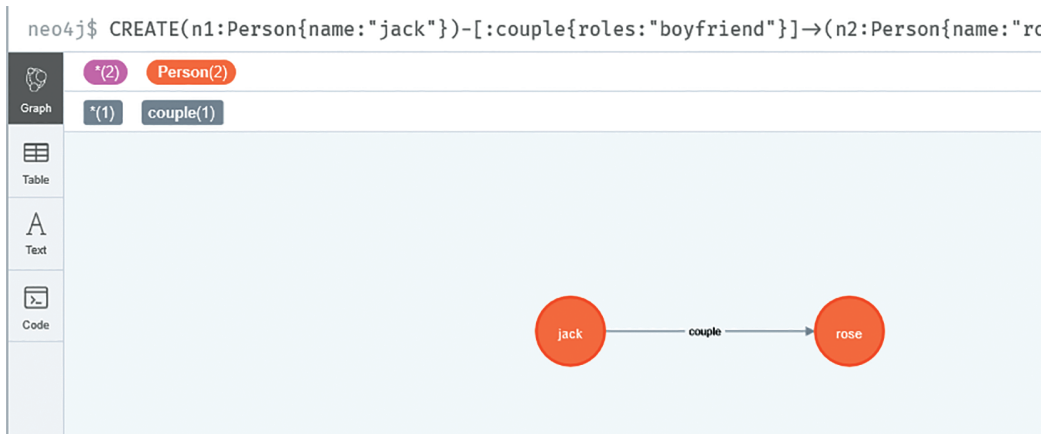


图 10 Neo4j操作页面展示

图11为该新闻的社交图谱,其中黄色代表点赞,绿色代表转发,蓝色代表评论。

图12为该新闻的知识图谱,不同颜色代表每个节点的不同属性,如人物、地点、事件等。

图13为该新闻的社交知识图谱,该图谱由社交图谱和知识图谱融合而成,在此处是以共同人物作为两个图谱之间的关联进行融合。

由图可以发现,Neo4j能够相对较为清晰地绘制出新闻的图谱,但是当信息量增大的时候,Neo4j所呈现出的图谱也会稍显复杂混乱。本文所展示的社交知识图谱只由一个单独的节点相关联,在实验中,更多图谱之间关联的点远不止一个,其对应的社交知识图谱若仅由Neo4j展示则会更加混乱。如何在尽可能

保证图相对清晰的情况下更好的进行图谱可视化展示也是未来可以进行探究的一个问题。

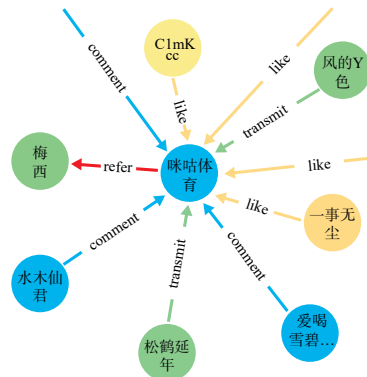


图 11 新闻社交图谱示例

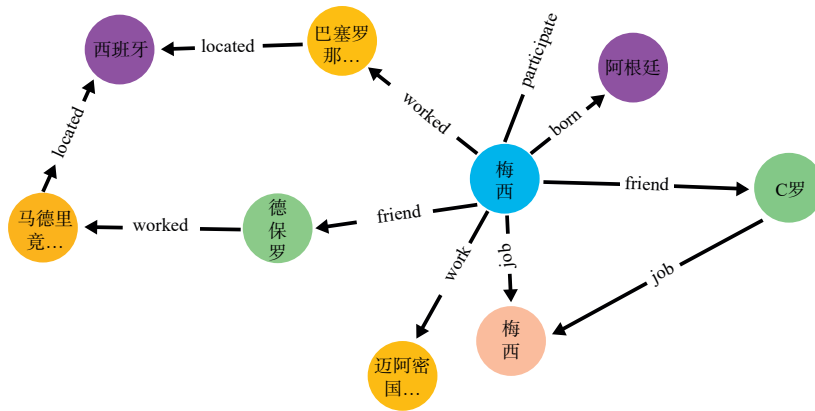


图12 新闻知识图谱示例

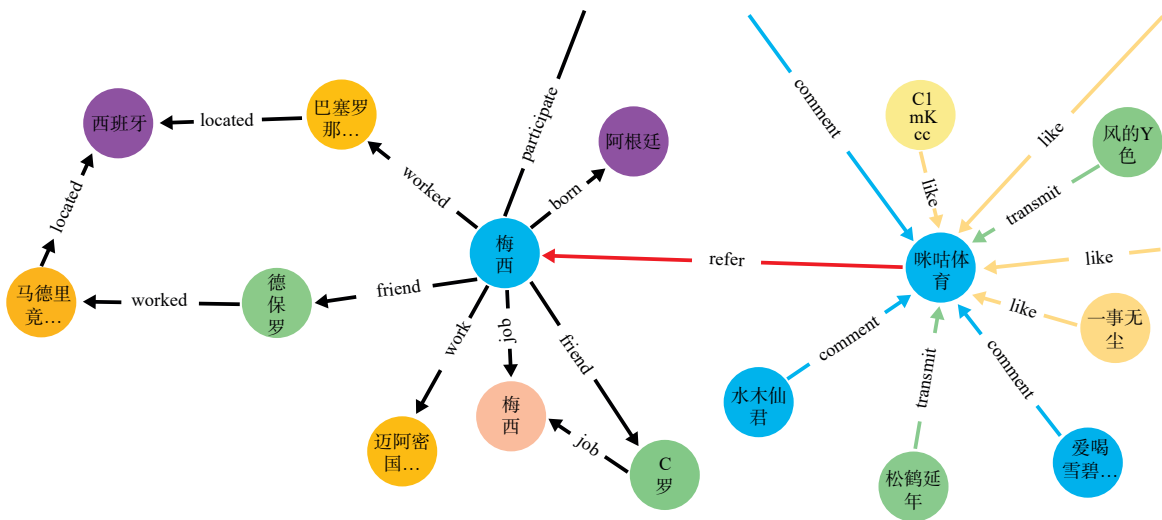


图13 新闻社交知识图谱示例

5 总结与展望

本文分别构建了面向虚假新闻的社交图谱和知识图谱,并利用实体对齐技术构建了对应的社交知识图谱,通过实验证明了基于社交知识图谱进行虚假新闻检测是有效的。整体来看,本文还存在社交信息不足、模型不够新颖、系统不够完善、缺乏对专业领域新闻及知识库的研究等问题,后续可以通过补充多平台社交信息、尝试预训练模型、构建包含社交信息的专业领域数据集、使用数据量更大的专业知识库等方法对实验进行完善。

参考文献 (References):

[1] 胡宏超, 谢新洲. 人工智能背景下虚假新闻的发展趋势与治理问题[J]. 新闻爱好者, 2023(10): 9-15.
 [2] Pachamuthu M S. Fake news detection in the medical field

using machine learning techniques[J]. International Journal of Safety and Security Engineering, 2022, 12(6): 723-727.
 [3] Nguyen V, Kazunari S, Preslav N, et al. FANG: leveraging social context for fake news detection using graph representation [C]// Proceedings of the 29th ACM International Conference on Information & Knowledge Management, 2020: 1165-1174.
 [4] 徐凡, 李明昊, 黄琪, 等. 知识图谱驱动的图卷积神经网络谣言检测模型[J]. 中国科学: 信息科学, 2023, 53(04): 663-681.
 [5] 陈开阳. 融合知识图谱的多模态虚假新闻检测研究[D]. 南昌: 江西师范大学, 2021.
 [6] Hu L, Yang T, Zhang L, et al. Compare to the knowledge: graph neural fake news detection with external knowledge [C]// Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing, 2021: 754-763.

- [7] Lao N, Cohen W W. Relational retrieval using a combination of path-constrained random walks [J]. *Mach Learn*, 2010(81): 53 - 67.
- [8] Yang Z, Tang J, Cohen W. Multi-modal bayesian embeddings for learning social knowledge graphs [C]// *Proceedings of the 25th International Joint Conference on Artificial Intelligence*, 2016: 2287-2293.
- [9] Meng Z, Lin R, Wu B. Graph neural networks-based preference learning method for object ranking [J]. *International Journal of Approximate Reasoning*, 2024(167): 109131.
- [10] Fu X, Yuan Y, Qiu H, et al. AGF-PPIS: a protein-protein interaction site predictor based on an attention mechanism and graph convolutional networks [J]. *Methods*, 2024(222): 142-151.
- [11] Sang W, Zhang H, Kang X, et al. Dynamic multi-granularity spatial-temporal graph attention network for traffic forecasting [J]. *Information Sciences*, 2024(662): 120230.
- [12] Wang J, Qu J, Zhao Z, et al. SMAAMA: a named entity alignment method based on Siamese network character feature and multi-attribute importance feature for Chinese civil aviation [J]. *Journal of King Saud University-Computer and Information Sciences*, 2023, 35(10): 101856.
- [13] Shi X, Li B, Chen L, et al. Bi-neighborhood graph neural network for cross-lingual entity alignment [J]. *Knowledge-Based Systems*, 2023(277): 110841.
- [14] Wang Z, Lv Q, Lan X, et al. Cross-lingual knowledge graph alignment via graph convolutional networks [C]// *Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing*, 2018: 349-357.
- [15] Vashishth S, Sanyal S, Nitin V, et al. Composition-based multi-relational graph convolutional networks [C]// *International Conference on Learning Representations*, 2020: 1-16.
- [16] 江旭晖, 沈英汉, 李子健, 等. 社交知识图谱研究综述 [J]. *计算机学报*, 2023, 46(02): 304-330.
- [17] MA J, GAO W, MITRA P, et al. Detecting rumors from microblogs with recurrent neural networks [C]// *Proceedings of the 25th International Joint Conference on Artificial Intelligence*, 2016: 3818-3824.
- [18] Ma J, Gao W, Wong K F. Detect rumors in microblog posts using propagation structure via kernel learning [C]// *Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics*, 2017, 1: 708-717.
- [19] Zubiaga A, Liakata M, Procter R, et al. Analysing how people orient to and spread rumours in social media by looking at conversational threads [J]. *PloS One*, 2016, 11(3): e0150989.
- [20] Chen M, Tian Y, Yang M, et al. Multilingual knowledge graph embeddings for cross-lingual knowledge alignment [C]// *Proceedings of the 26th International Joint Conference on Artificial Intelligence*, 2017: 1511-1517.
- [21] Liu Z, Cao Y, Pan L, et al. Exploring and evaluating attributes, values, and structures for entity alignment [J]. *Computing Research Repository*, 2020: 6355-6364.
- [22] 郭亚杰, 纪淑娟, 曹宁, 等. 基于 BiLSTM 的社交媒体虚假新闻检测 [J]. *软件导刊*, 2022, 21(05): 43-48.
- [23] Li C, Peng H, Li J, et al. Joint stance and rumor detection in hierarchical heterogeneous graph [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 33(6): 2530-2542.
- [24] Mao X, Wang W, Wu Y, et al. From alignment to assignment: frustratingly simple unsupervised entity alignment [C]// *Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing*, 2021: 2843-2853.

编辑:赵志军