

一种融合实体描述和拓扑结构的知识图谱补全方法

韩道军, 李云松, 张俊涛, 王泽民

引用本文

韩道军, 李云松, 张俊涛, 王泽民. 一种融合实体描述和拓扑结构的知识图谱补全方法[J]. 计算机科学, 2025, 52(5): 260-269.

HAN Daojun, LI Yunsong, ZHANG Juntao, WANG Zemin. [Knowledge Graph Completion Method Fusing Entity Descriptions and Topological Structure](#) [J]. Computer Science, 2025, 52(5): 260-269.

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)

[融合定长Seq2Seq网络的中文成语智能纠错模型](#)

Intelligent Error Correction Model for Chinese Idioms Fused with Fixed-length Seq2Seq Network
计算机科学, 2025, 52(5): 227-234. <https://doi.org/10.11896/jsjcx.240400035>

[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>

[面向无人机航拍图像的YOLOv8目标检测改进算法](#)

An Improved YOLOv8 Object Detection Algorithm for UAV Aerial Images
计算机科学, 2025, 52(4): 202-211. <https://doi.org/10.11896/jsjcx.240500042>

[基于虹膜纹理感知的自适应关联学习方法](#)

Adaptive Contextual Learning Method Based on Iris Texture Perception
计算机科学, 2025, 52(4): 185-193. <https://doi.org/10.11896/jsjcx.250100022>

[基于边缘约束和改进Swin Unetr的复杂器官分割方法](#)

Complex Organ Segmentation Based on Edge Constraints and Enhanced Swin Unetr
计算机科学, 2025, 52(4): 177-184. <https://doi.org/10.11896/jsjcx.240600007>

一种融合实体描述和拓扑结构的知识图谱补全方法

韩道军^{1,2} 李云松² 张俊涛^{1,2} 王泽民²

1 河南省智能技术与应用工程技术研究中心 河南 开封 475004

2 河南大学计算机与信息工程学院 河南 开封 475004

(hdj@henu.edu.cn)

摘要 知识图谱补全旨在预测给定三元组中缺失的实体和关系,以增强知识图谱的完整性和质量。现有的知识图谱补全方法通常只考虑三元组自身的结构信息或者是实体单一的附加信息(如实体的文本描述或拓扑结构信息),而忽略了融合多种附加信息来增强实体的特征信息,从而导致现有方法补全缺失实体时性能不佳。针对这个问题,提出一种融合实体文本描述和拓扑结构信息的知识图谱补全方法(FuDS-KGC),用于改善知识图谱补全任务的性能。该方法首先通过 Transformer 和注意力机制提取实体文本描述中特定于关系的特征表示,以增强实体描述的代表特征信息。然后,构建实体的一阶邻居子图,并通过图注意力网络获得实体的拓扑结构特征。最后,设计一种动态门控融合机制,融合实体的文本描述和拓扑结构特征,以增强实体的综合特征表示。在 FB15k-237 和 WN18RR 两个数据集上进行实验,实验结果证明了 FuDS-KGC 的有效性。

关键词 知识图谱补全;Transformer;实体描述;注意力机制;拓扑结构

中图分类号 TP391.1

Knowledge Graph Completion Method Fusing Entity Descriptions and Topological Structure

HAN Daojun^{1,2}, LI Yunsong², ZHANG Juntao^{1,2} and WANG Zemin²

1 Henan Engineering Research Center of Intelligent Technology and Application, Kaifeng, Henan 475004, China

2 School of Computer and Information Engineering, Henan University, Kaifeng, Henan 475004, China

Abstract Knowledge graph completion aims to predict missing entities and relationships in given triplets to enhance the completeness and quality of the knowledge graph. Existing knowledge graph completion methods typically only consider the structural information of triplets or the individual additional information of entities, such as textual descriptions or topological structure information. This overlooks the fusion of multiple types of additional information to enhance entity feature information, leading to suboptimal performance in completing missing entities. To address this issue, this paper proposes a knowledge graph completion method integrating entity text descriptions and topological structure information, referred to as FuDS-KGC, to enhance the performance of knowledge graph completion tasks. This method first extracts relationship-specific feature representations from entity textual descriptions using Transformer and attention mechanisms to enhance the representation feature information of entity descriptions. Next, it constructs first-order neighbor subgraphs for entities and obtains topological structure features through a graph attention network. Finally, a dynamic gated fusion mechanism is designed to integrate entity textual descriptions and topological structure features to enhance the comprehensive feature representation of entities and overcoming the limitation of existing research focusing on the fusion of singular additional information. Experimental results on FB15k-237 and WN18RR datasets demonstrate the effectiveness of FuDS-KGC.

Keywords Knowledge graph completion, Transformer, Entity descriptions, Attention mechanism, Topological structure

1 引言

知识图谱(Knowledge Graph, KG)是将真实世界的事实知识抽象为一个由数十亿个三元组组成的复杂网络图^[1]。知

识图谱揭示实体之间的关系,在信息检索^[2]、问答系统^[3]和推荐系统^[4]等领域发挥着重要作用。虽然已经从真实世界中提取数以百万计的实体及其关系,但是大规模知识图谱仍面临着不完备的问题^[5],因此知识图谱补全(Knowledge Graph

到稿日期:2024-03-01 返修日期:2024-08-01

基金项目:河南省高校青年骨干教师基金(2020GGJS027);国家自然科学基金(42371433,62307012);河南省科技攻关项目(232102211056,242102320160)

This work was supported by the Foundation of University Young Key Teacher of Henan Province(2020GGJS027), National Natural Science Foundation of China(42371433,62307012) and Scientific and Technological Key Project in Henan Province(232102211056,242102320160).

通信作者:张俊涛(juntaozhang@henu.edu.cn)

Completion, KGC) 成为了知识图谱领域的主要挑战之一。领域专家提出了知识图谱嵌入 (Knowledge Graph Embedding, KGE)^[6] 方法,通过在低维连续的向量空间中学习知识图谱中实体及其关系的嵌入表示来解决这个问题。

在知识图谱中,不完备的三元组通常以 $(?, r, t)$, $(h, ?, t)$ 和 $(h, r, ?)$ 的形式存在,本文通过已知实体或者关系来补全知识图谱中缺失的信息。如图 1 所示,“United States”“Donald Trump”“New York”等是知识图谱中的实体,实体之间的有向箭头表示知识图谱中的关系。由图 1 可知,知识图谱中事实 (Donald Trump, Born_in, New York) 和 (New York, Is_city_of, United States) 是已知的,本文想要获取 Donald Trump 的国籍信息,即 (Donald Trump, Nationality, ?) 是未知的,那么这个缺失实体就可以通过 KGC 模型进行补全,然后将候选实体如“United States”排在最佳位置而实现补全。实际中,除了利用实体自身的三元组信息外,还可以融合实体的附加信息(如文本描述和拓扑结构信息)来增强实体的特征表示,从而提高知识图谱中实体之间补全的准确性。在图 1 中,与实体 (“United States”) 连接的实体 (“Washington” “Apple Inc” “Google” 和 “New York”) 称为其拓扑结构,而用虚线与 “United States” 相连的称为其文本描述信息。

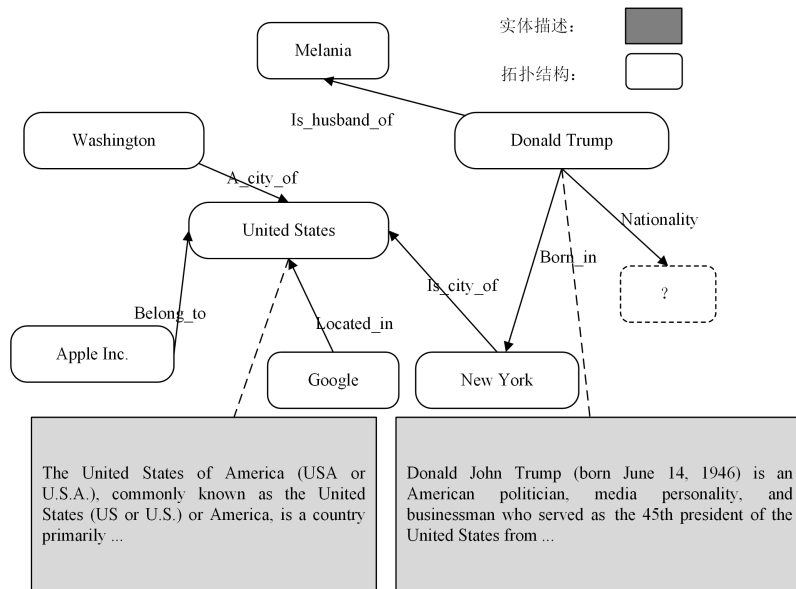


图 1 知识图谱补全示例

Fig. 1 Example of knowledge graph completion

在知识图谱补全领域,许多知识图谱嵌入模型利用实体的文本描述信息或者拓扑结构信息来提升知识图谱补全的准确性。例如,现有研究工作中融合了实体描述信息的模型有结合实体描述的知识图谱表示学习 (DKRL)^[7]、基于语义空间投影的知识图谱嵌入模型 (SSP)^[8] 和联合结构和文本编码的知识图谱表示学习 (JSTE)^[9] 等,它们将实体的文本描述信息作为自身三元组结构信息的补充,进一步丰富实体的特征表示,从而提升了知识图谱补全的性能。同样地,融合了拓扑结构信息的模型有多关系图神经网络模型 (Graph Convolutional Network Model for Multi-relational Graphs, CompGCN)^[10] 和结合实体拓扑结构的图注意力网络模型 (KBGAT)^[11] 等,它们从实体的邻域中提取实体特征来更新实体的特征表示,进而提升知识图谱补全的准确性。然而,现有融合实体文本描述信息的模型在使用文本描述时,没有对实体的文本描述信息进行过滤,导致实体特征的增强效果较差,降低了补全的性能。此外,现有的研究工作仅采用实体的文本描述信息或者拓扑结构信息作为实体特征的补充,并没有考虑如何融合两者信息作为实体的特征补充。

为解决上述问题,本文提出一种融合实体描述和拓扑结构的知识图谱补全方法 (A Knowledge Graph Completion Method Fusing Entity Descriptions and Topological Structure, FuDS-KGC)。首先,引入 Transformer 编码器模型对实

体的文本描述进行编码,得到实体的文本特征表示。然后,采用注意力机制获取实体文本特征表示与关系相关的语义信息,使得实体描述信息精确表示,以解决实体目标描述特征表示不准确的问题。其次,根据实体的一阶邻居集构建实体子图,通过实体在不同关系下的一阶邻居,重构实体表示集合,并对实体表示集合进行语义融合生成实体的语义表示。根据实体的语义表示使用图注意力网络计算每个实体在知识图谱中的拓扑结构信息,以获得实体的拓扑结构特征表示。最后,设计一种动态门控融合机制来融合实体的描述特征表示和拓扑结构特征,以获得实体的综合特征表示,从而提升补全的性能,解决附加信息单一的问题。本文在 FB15k-237 和 WN18RR 两个数据集上进行了实验,实验结果表明 FuDS-KGC 在知识图谱补全任务中优于对比方法,这证明了 FuDS-KGC 的有效性。

2 相关工作

2.1 基于 KGE 的知识图谱补全方法

基于知识图谱嵌入 (Knowledge Graph Embedding, KGE) 的知识图谱补全方法主要分为 3 类:基于平移距离的方法、基于语义匹配的方法和基于神经网络的方法。

2.1.1 基于平移距离的方法

基于平移距离方法利用平移或旋转等几何运算来计算三

元组得分,通过衡量头实体和尾实体之间的距离来评估得分,从而完成补全。TransE^[12]是平移距离方法的先驱,它将三元组中的关系表示为实体向量间的平移操作,旨在满足 $h+r=t$ 的条件。虽然TransE在建模一对一关系方面表现出色,但是在建模复杂关系方面存在不足。为了克服这一困难,许多后续的变体方法(如TransH^[13],TransR^[14]和TransD^[15]等)对不同关系中实体的不同语义进行建模,以增加补全方法对实体不同语义建模的灵活性。这些变体方法都试图对“对称/反对称、逆关系和复合关系”模式中的一种或几种关系进行建模,但没有一种现有方法能够对这3种关系同时进行建模。针对这一问题,Sun等提出了RotatE^[16](Knowledge Graph Embedding by Relational Rotation in Complex Space),它将每个关系定义为头实体到尾实体的旋转,利用复数空间的旋转不变性推断所有的关系模式。进一步地,TransERR模型^[17]采用了一种新颖的方法,在超复数值空间中编码知识图谱,增加了模型挖掘实体间潜在信息的灵活性。该模型通过可学习的单位四元数对实体进行旋转,精确地最小化翻译距离,并通过数学证明展示了其在模拟多种关系模式(包括对称、反对称、反转、组合和子关系模式)方面的有效性。上述方法对知识图谱补全任务起到了关键性作用,推动了其发展并证实了其存在价值。

2.1.2 基于语义匹配的方法

语义匹配的方法指,知识图谱补全方法使用线性或双线性函数建立实体和关系之间的联系,并将实体和关系表示分解到不同维度来计算头尾实体之间的语义匹配可信度。例如,RESICAL^[18]采用矩阵分解的补全方法,将三元组表示为三阶张量,实体映射为向量,关系建模为关系矩阵,用于捕获头尾实体向量不同维度间的交互。RESICAL相较于之前的补全方法可以处理复杂关系,并具备对稀疏数据的处理能力。DistMult^[19]采用双线性函数学习表示,将每个关系表示为对角矩阵,从而加速训练过程和收敛速度,简化了补全方法的复杂性,降低了计算成本。ComplEX^[20]引入了复数,将每个实体和关系都用实部和虚部表示,使得模型能够捕捉更复杂的关系,解决了DisMult补全方法不能建模反对称关系的问题。Zhang等^[21]提出了DURA正则化器,它通过增加原始与对偶模型评分函数的交叉项来减少过拟合,该交叉项基于张量分解,其平方形式可强化正则化效果。Chen等^[22]提出结合多重嵌入表示的中文知识图谱补全方法MER-Tuck,该方法利用外部的语义补充来加强矩阵分解模型的学习能力。上述方法与平移距离方法相比,在知识图谱补全任务上有着更高的性能和效率。但是,平移距离方法和语义匹配方法由于方法简单、参数较少,很难捕捉到知识图谱中的复杂信息。

2.1.3 基于神经网络的方法

基于神经网络的方法在最近的KGC研究中取得了显著的性能。ConvE^[23]是首次使用卷积模型学习向量表示的方法,它利用2D卷积和多层非线性特征来模拟实体和关系间的交互进行链接预测,获得了很好的参数利用率。但是该模型并没有考虑三元组中相同维度之间的全局关系,只将头实体和关系表示输入到卷积层中,输入结果与尾实体计算得分。ConvKB^[24]继承了ConvE的卷积操作,并将头、尾实体和关系

同时送入到卷积层中计算得分,同时还保留了平移距离方法的平移特性。Zou等^[25]提出了一种基于邻域聚合与CNN的知识图谱实体类型补全方法(NACE2T)。该方法采用编码器-解码器的结构,通过注意力机制对关系信息进行编码,并为实体领域内的每个关系-实体对分配不同的权重,以有效聚合实体与关系的信息,从而准确推断出知识图谱中确实的实体类型。与传统的KGC方法相比,上述方法利用卷积参数共享的优势,以更少的参数学习更好的表示。

2.2 融合附加信息知识图谱补全方法

2.1节中提到的方法主要依赖于知识图谱的结构信息(即三元组自身结构信息),而引入附加信息作为三元组结构信息的补充,能够进一步提升知识图谱补全的性能。本节从融合知识图谱中实体的文本描述和拓扑结构的两类附加信息来介绍知识图谱补全的相关方法。

2.2.1 融合实体描述的知识图谱补全方法

最早的文本描述模型可以追溯到NTN模型^[26],它将知识图谱三元组与实体的文本描述信息分开进行建模,没有考虑它们之间的信息交互。近年来,实体的文本描述信息作为三元组结构信息的补充,被纳入到知识图谱补全模型中以提高模型的性能。例如Wang等^[27]在知识图谱补全任务中考虑文本信息,使用Word2Vec编码文本的词嵌入表示,并利用TransE模型学习知识表示以实现知识图谱补全。结合实体描述的知识图谱表示学习DKRL模型,Dai等^[28]分别使用卷积神经网络(CNN)^[29]和TransR获得基于文本描述和三元组结构的表示,并为每个实体设置关系特定的投影,以区分实体空间和关系空间,获得更为高效的知识表示能力,从而提升补全的准确性。不同于上述线性组合的方法,Zhong等^[30]提出了一种基于实体描述的对齐知识和文本嵌入模型(ATE),它根据锚文本与实体的对应关系,使得文本中实体对应的词表示与知识库中的实体表示尽可能接近,实现文本与知识库融合表示学习,从而提升知识图谱补全的性能。为了进一步增强文本描述和三元组之间的关联,Xiao等^[31]提出了基于语义空间投影的知识图谱补全模型,它通过将三元组和文本描述投影到语义子空间,来捕捉它们之间的强相关性,使嵌入的拓扑结构和语义更加适合。EDA-KGC模型^[32]通过整合实体描述和网络结构来优化实体及关系的表示,显著提升了性能。该模型包括3个核心组件:1)表示组件,通过实体描述进行预训练,以获取初始表示;2)深度交互组件,提取实体和关系之间的交互特征;3)推理组件,利用这些特征进行矩阵运算,快速预测尾实体的概率分布,从而提高推理效率并增强模型对大规模知识图谱的处理能力。

2.2.2 融合拓扑结构的知识图谱补全方法

知识图谱中每个实体都有对应的拓扑结构,它被认为是丰富实体特征表示的有效信息。关系图卷积网络(RGCN)^[33]首次用于处理知识图谱,它通过知识图谱中实体的拓扑结构信息,来更新实体的特征表示,增加可训练参数的数量,以提升补全的性能。在此基础上,CompGCN^[10]采用了传统知识图谱嵌入技术的评分函数,建模中心实体与不同类别的相邻实体之间的关系,取得了较高准确率。DRRGAT模型^[34]提出了一个具有动态关系表示和全局信息的图注意力网络来补全

知识图谱,以动态关系表示学习不同三元组中相同关系的独特表示,并将全局嵌入机制纳入图注意力网络,获取实体和关系的全局信息。然而,基于拓扑结构的知识图谱补全模型在处理大规模知识图谱时面临着计算复杂高的问题。

3 FuDS-KGC

本章首先给出知识图谱补全任务的简介,然后介绍 FuDS-KGC 的整体框架及其各个模块的细节描述。

3.1 任务简介

知识图谱补全的目标是预测并补全三元组中缺失的

实体。给定知识图谱 G 中特定的三元组 $T=(h,r,t)$,其中 $h,t \in E$ 是实体集合, $r \in R$ 是关系集合。KGC 可以表示为 $(?,r,t),(h,r,?)$,即基于已知的 2 个元素预测缺失的元素。本文的目标是融合实体的文本描述与拓扑结构,以增强其综合特征,从而通过链接预测完成知识图谱补全。

3.2 整体框架

FuDS-KGC 由实体描述表示学习模块、实体拓扑结构表示学习模块、融合学习模块和链接预测 4 部分组成,它的整体框架如图 2 所示。

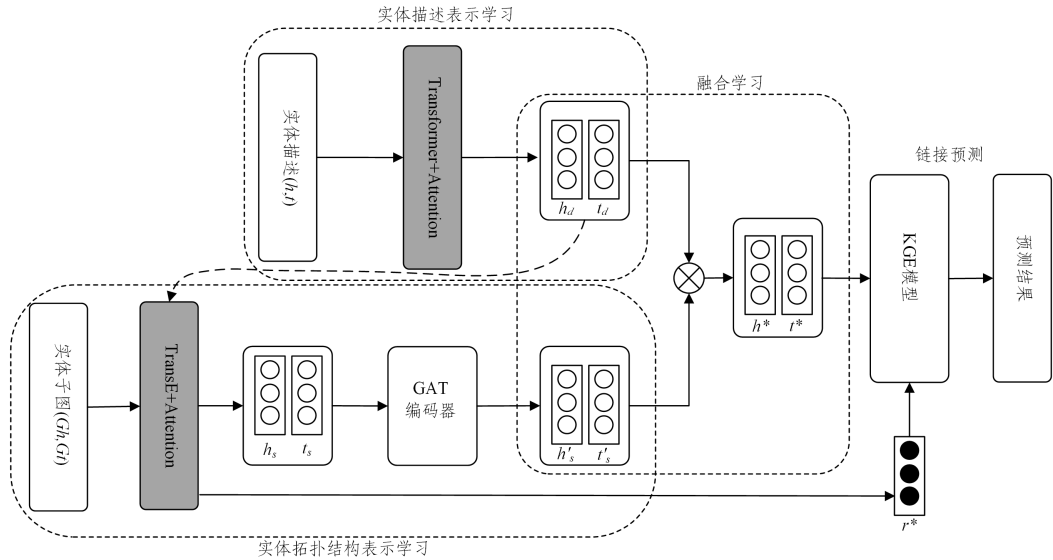


图 2 FuDS-KGC 的整体框架

Fig. 2 Overall framework of FuDS-KGC

实体描述表示学习模块将实体描述作为输入,并利用 Transformer 编码器和关系注意机制,将头实体和尾实体的文本描述编码为各自的向量表示,分别为 h_d 和 t_d 。

实体拓扑结构表示学习模块基于一阶拓扑邻居创建实体子图,并使用 TransE 模型计算子图中实体与关系的特征表示,分别为 h_s, t_s 和 r 。然后,根据图注意力网络计算知识图谱中实体的拓扑结构信息,获得实体的拓扑结构特征表示,分别表示为 h'_s 和 t'_s 。

融合学习模块利用动态门控机制,将头实体和尾实体描述的特征表示 h_d 和 t_d 与实体的拓扑结构嵌入表示 h'_s 和 t'_s 相融合,得到实体的综合特征表示,分别为 h^* 和 t^* 。

链接预测将实体的综合特征表示 h^*, t^* 和 r 作为输入,使用 TransE 进行链接预测,从而完成知识图谱补全。

3.3 实体描述表示学习模块

实体的文本描述包含与实体相关的丰富语义特征,准确、高效地从实体文本描述中提取关键的语义特征将显著提升知识图谱补全模型的性能。首先,将头尾实体的文本描述作为输入,然后采用 Transformer 编码器和关系注意力机制,捕获实体 h 或 t 的文本描述中与关系 r 相关的丰富语义信息,以捕获实体的文本描述信息中与关系相关的实体描述特征表示。实体描述表示学习模块由输入层、Transformer 编码层和关系注意力层 3 个层组成,如图 3 所示。

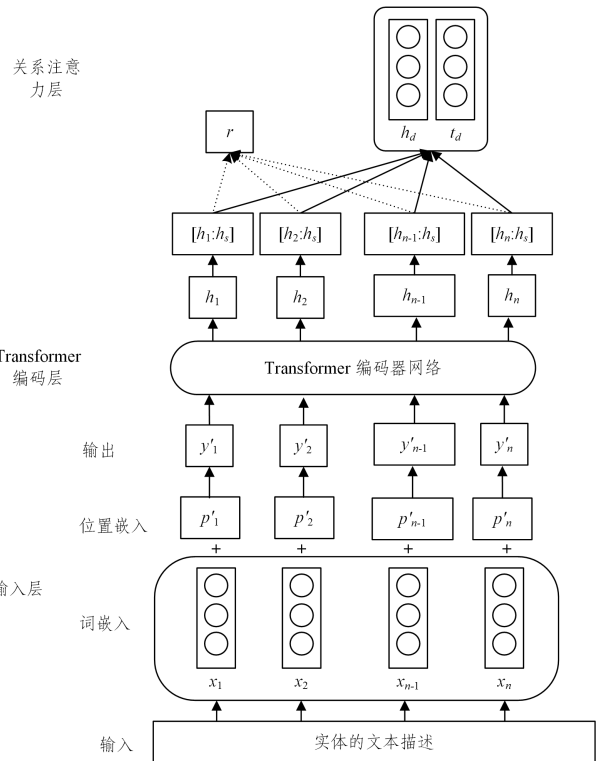


图 3 实体描述表示学习模块

Fig. 3 Entity description representation learning module

3.3.1 输入层

在输入层中,本节将实体文本描述的词嵌入表示和位置嵌入表示拼接起来,将得到的句子嵌入表示作为 Transformer 编码层的输入,从而表示相应实体的文本描述信息。

首先,利用 Word2Vec 对大量的实体文本描述进行编码,获得词嵌入矩阵 $\mathbf{Word} \in R^{k \times d}$,其中 k 是实体描述的词汇总量。然后通过在所获得词嵌入矩阵中进行查找,获取实体描述 $des = \{\omega_1, \omega_2, \dots, \omega_n\}$,从而得到实体描述的词嵌入矩阵 $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$ 。其中, $\mathbf{X} \in R^{n \times d}$,而 $x_i \in R^{1 \times d}$ 表示实体描述中第 i 个单词的嵌入, d 表示单词嵌入维度, n 表示实体描述的长度。

$$x_i = \text{Word2Vec}(\omega_i) \quad (1)$$

其中, ω_i 表示文本描述 des 中的第 i 个单词, x_i 是 Word2Vec 编码后的单词嵌入向量表示。

为了获取实体描述的序列顺序,随机初始化位置嵌入矩阵 $\mathbf{pos} \in R^{k \times d}$,通过查询 \mathbf{pos} 的每个位置索引并将其转换为位置嵌入,从而得到位置嵌入矩阵 $\mathbf{P} = \{p_1', p_2', \dots, p_n'\}$,该位置嵌入矩阵 \mathbf{P} 在训练过程中进行更新。其中, $p_i' \in R^{1 \times d}$ 表示描述中第 i 个单词的位置嵌入, n 是实体描述的长度。最后,将单词嵌入矩阵和位置嵌入矩阵拼接,得到输入层的输出向量 $\mathbf{Y} = \{y_1, y_2, \dots, y_n\}$,其中, $y_i \in R^{2d \times 1}$ 是 x_i 和 p_i' 的拼接。

3.3.2 Transformer 编码层

自注意力机制是 Transformer 编码器的核心,它能够同时关注输入序列中所有位置的信息,捕获全局的上下文信息。为了从实体描述中获取更多的语义信息,采用了一个由 6 个相同的堆叠层组成的 Transformer 编码器。其中,每个层包含两个子层:多头注意力层和位置前馈网络。残差连接用于绕过每个子层,并在每个层的最后进行层归一化。具体实验步骤如下:

1) 利用自注意力机制,使得查询向量 \mathbf{Q} 、键向量 \mathbf{K} 和值向量 \mathbf{V} 与实体文本描述嵌入表示 \mathbf{Y} 相等。注意力的计算式为:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{QK}^T}{\sqrt{d}}\right)\mathbf{V} \quad (2)$$

其中, Attention 表示注意力, Softmax 表示非线性激活函数, \mathbf{K}^T 表示键向量的转置, d 表示维度。

2) 对于每个注意力头,通过一组随机的权重矩阵 \mathbf{W}_k^Q , \mathbf{W}_k^K , \mathbf{W}_k^V 将查询向量 \mathbf{Q} 、键向量 \mathbf{K} 以及值向量 \mathbf{V} 映射到不同的矩阵中。其计算式为:

$$\text{head}_k = \text{Attention}(\mathbf{QW}_k^Q, \mathbf{KW}_k^K, \mathbf{VW}_k^V) \quad (3)$$

其中, head_k 表示第 k 个注意力头。

3) 将 k 个注意力头进行拼接,得到一个融合了多个注意力头的矩阵 $\mathbf{Multihead}$ 。其计算式为:

$$\mathbf{Multihead} = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_k)\mathbf{W}^o \quad (4)$$

其中, $\mathbf{Multihead}$ 表示融合了多个注意力头的矩阵, Concat 表示拼接操作, \mathbf{W}^o 表示转换矩阵, k 表示注意力头个数。

4) 根据输入向量 \mathbf{Y} 和融合了多个注意力头的矩阵 $\mathbf{Multihead}$,使用两层的残差连接并进行层归一化处理(见式(5)和式(7)),以及两个使用 ReLU 函数激活的线性层(见式(6)),来获得实体的文本描述特征表示。具体的计算式如下:

$$\mathbf{Z} = \text{LayerNorm}(\mathbf{Y} + \mathbf{MultiHead}) \quad (5)$$

$$\mathbf{FFN}(\mathbf{Z}) = \text{ReLU}(\mathbf{Z}\mathbf{W}_1 + \mathbf{b}_1)\mathbf{W}_2 + \mathbf{b}_2 \quad (6)$$

$$\mathbf{H} = \text{LayerNorm}(\mathbf{Z} + \mathbf{FFN}(\mathbf{Z})) \quad (7)$$

其中, \mathbf{Z} 表示层归一化结果向量表示, LayerNorm 表示层归一化, \mathbf{Y} 为输入向量, \mathbf{FFN} 表示全连接网络, ReLU 表示非线性激活函数, \mathbf{b}_1 和 \mathbf{b}_2 表示偏置向量, \mathbf{W}_1 和 \mathbf{W}_2 表示权重参数矩阵, \mathbf{H} 表示实体的描述特征表示。

5) Transformer 编码器输出包含了每个单词的上下文语义信息,表示为 $\mathbf{H} = \{h_1, h_2, \dots, h_n\}$,作为关系注意层的输入。

3.3.3 关系注意力层

给定事实三元组 (h, r, t) ,为了过滤与关系特定的实体描述特征表示,采用注意力机制获取实体的描述特征表示中与关系相关的语义信息,得到实体的目标描述特征表示。

首先,为了获得实体描述的全局向量表示,一种简单直接的方法是对实体描述中的词向量进行平均。然而,这种方法没有区分处理实体描述中的每个词,也没有考虑与三元组中关系相关的词的重要性。因此,本文采用了一种关系注意力机制来计算实体描述中每个词的权重,并以此得到实体描述的全局表示,即实体描述中词向量的加权和。

其次,为了识别实体描述中与实体和三元组中的关系密切相关的词,本文使用了全连接神经网络来计算实体描述中每个单词的权重。该网络的输入是头实体表示 h_s 和关系表示 r (这两者由 TransE 模型预训练得到),以及每个词的上下文特征表示 h_f 。

$$\alpha_f = \frac{\exp(\mathbf{W}[h_f; h_s] + \mathbf{Vr})}{\sum_{j=1}^N \exp(\mathbf{W}[h_j; h_s] + \mathbf{Vr})} \quad (8)$$

其中, α_f 表示实体的描述特征表示中第 f 个单词的权重; \exp 表示以自然常数为底的指数函数; h_f 表示实体的描述特征表示中第 f 个单词; h_s 表示头实体的语义表示; \mathbf{V} 表示参数向量,通过学习过程优化得到,目的是为了在计算权重时调整不同词的贡献; \mathbf{r} 表示关系向量,是由 TransE 模型进行预训练得到的; N 表示单词个数; h_j 表示实体的描述特征表示中第 j 个单词。

最后,将实体描述的全局表示形式作为实体描述中单词表示形式的加权和,以获得头实体的目标描述特征表示 h_d ,其计算式为:

$$h_d = \sum_{f=1}^N \alpha_f h_f \quad (9)$$

同理,得到尾实体目标描述特征的表示 t_d 。

3.4 实体拓扑结构表示学习模块

在不同的三元组中,对于不同的关系,同一个实体应该具有不同的语义表示。例如,三元组(李四,领导,王五)表示“王五”是“李四”的领导,而三元组(李四,同事,小红)表示“小红”是“李四”的同事。在这种情况下,“李四”的特征表示应该根据不同的关系而有所不同。因此,本文提出了实体拓扑结构表示学习模块,用于获取特定于关系的实体表示。首先基于知识图谱构建实体子图,并使用 TransE 知识图谱嵌入模型对实体和关系的向量表示进行预训练。然后采用注意力机制来获得特定于关系的实体表示,并引入了第 3.3 节中的实体描述表示作为注意力,用于获得相应的实体特征表示。实体拓扑结构表示学习模块的整体结构如图 4 所示。

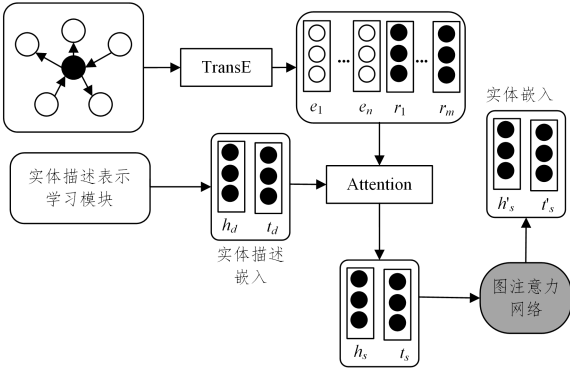


图4 实体拓扑结构表示学习

Fig.4 Entity topological structure representation learning

实体拓扑结构表示学习的具体步骤如下:

1) 对于知识图谱中的某一实体 i , 基于其一阶邻居节点构建实体子图。随后, 利用 TransE 模型对该子图中的实体和关系进行预训练, 以获得向量表示。最后, 通过考虑实体在不同关系下的一阶邻居来重构实体表示, 表示为 $S_i = \{(t_1 - r_1), \dots, (h_1 + r_2), \dots, (i)\}$, 其中 $(t_1 - r_1)$ 表示新的头实体表示, $(h_1 + r_2)$ 表示新的尾实体表示。

预训练嵌入的具体形式如下:

$$h, r, t = \text{TransE}(e_h, e_r, e_t) \quad (10)$$

其中, e_h, e_r 和 e_t 表示初始的头实体、关系实体和尾实体的向量表示; h, r 和 t 表示预训练后得到的头实体、关系实体和尾实体的向量表示。

2) 基于从实体描述表示学习模块(见第 3.3 节)获得的头实体 h_d 和尾实体 t_d 的目标描述表示, 本文使用它们来提取关于不同关系的头实体 h 和尾实体 t 的属性信息。随后, 对实体表示集 S_i 进行语义交互, 生成头尾实体的语义表示 h_s 和 t_s , 实现了同一实体在不同关系的三元组中展现出不同的语义表示。具体计算式如下:

$$h_s = \sum_{i=1}^{k+1} \text{softmax}\left(\frac{\mathbf{S}_{h_i}^T \cdot h_d}{\sqrt{d}}\right) \mathbf{S}_{h_i} \quad (11)$$

$$t_s = \sum_{i=1}^{k+1} \text{softmax}\left(\frac{\mathbf{S}_{t_i}^T \cdot t_d}{\sqrt{d}}\right) \mathbf{S}_{t_i} \quad (12)$$

其中, \mathbf{S}_{h_i} 表示 S_h 集合中的第 i 个向量表示; \mathbf{S}_{t_i} 表示 S_t 集合中的第 i 个向量表示; d 表示实体描述表示的维度; k 表示 S_h 或 S_t 集合中的向量数量; Softmax 是非线性激活函数。

3) 将头实体和尾实体的语义表示 h_s 和 t_s 作为图谱的初始节点表示, 并将其输入到图注意力网络中进行特征增强, 以获得实体的拓扑结构特征表示。

首先, 计算图谱中第 i 个节点和第 j 个节点之间的注意力权重。其计算式如下:

$$\alpha_{ij} = \frac{\exp(\text{LeakyRelu}(\mathbf{a}^T [\mathbf{W}e_i \parallel \mathbf{W}e_j]))}{\sum_{k \in N_i} \exp(\text{LeakyRelu}(\mathbf{a}^T [\mathbf{W}e_i \parallel \mathbf{W}e_j]))} \quad (13)$$

其中, e_i 和 e_j 分别代表图谱中第 i 个节点和第 j 个节点的特征; \mathbf{W} 表示节点的初始权重矩阵; \parallel 表示拼接操作; \mathbf{a} 表示注意力机制的权重向量; \mathbf{T} 表示转置操作; LeakyRelu 是非线性激活函数; N 表示节点 i 的邻居集合。

然后, 对注意力权重 α_{ij} 和图谱中每个邻居节点的特征进行线性组合并归一化, 获取节点 i 的最终特征表示。

$$h_i = \sigma\left(\sum_{j \in N_i} \alpha_{ij} \mathbf{W}h_j\right) \quad (14)$$

其中, σ 代表非线性激活函数, h_j 是邻居节点的特征表示。

最后, 基于实体的语义表示使用图注意力网络计算每个实体在知识图谱中的拓扑结构信息, 从而获得实体的拓扑结构特征表示。可以得到, 头实体和尾实体的表示分别为 h'_s 和 t'_s :

$$\begin{aligned} h'_s &= \text{GAT}(h_s) \\ t'_s &= \text{GAT}(t_s) \end{aligned} \quad (15)$$

其中, $\text{GAT}(\cdot)$ 表示图注意力网络的聚合和更新过程。

3.5 融合学习模块

实体描述与实体的拓扑结构信息作为实体额外的附加信息能够丰富实体的特征表示。为了充分利用这两种附加信息, 本文提出了一个动态门控融合机制, 将实体描述特征表示和实体拓扑结构特征表示进行融合, 以获得头实体和尾实体的综合特征表示。

动态门控融合机制首先利用头实体描述特征表示 h_d 和头实体特征表示 h_s 计算权重门向量 \mathbf{g} 。随后, 使用 \mathbf{g} 来融合 h_d 和 h_s , 得到综合特征表示 h^* 。具体计算式如下:

$$\mathbf{g} = \text{softmax}(\mathbf{W}[h_d; h_s'] + \mathbf{b}_1) \quad (16)$$

$$h^* = \mathbf{g} \odot h_d + (1 - \mathbf{g}) \odot h_s' \quad (17)$$

其中, \mathbf{g} 表示权重门参数, \odot 表示 hadamard 乘积, softmax 表示非线性激活函数, h_d 表示头实体目标描述特征表示, h_s' 表示头实体的拓扑结构特征表示, $\mathbf{W}[h_d; h_s']$ 表示 h_d 和 h_s' 拼接得到的中间表示, \mathbf{b}_1 表示偏置向量。

同理, 可以得到尾实体的综合特征表示 t^* 。

3.6 链接预测

在 FuDS-KGC 框架中, 本文使用 TransE 知识图谱嵌入模型进行链接预测, 以实现知识图谱补全。为了预测三元组中缺失的实体, 利用 TransE 的评分函数 $F(h, r, t)$ 计算每个潜在三元组的可信度分数。然而, 与现有方法直接将实体和关系的特征表示输入到评分函数中不同, 本文将融合学习模块(见第 3.5 节)的结果 h^* 和 t^* 作为实体特征表示。

在模型训练阶段, 给定一组事实三元组 T , FuDS-KGC 采用伯努利抽样策略生成负采样集 T' 。对于被视为正样本的三元组 $(h, r, t) \in T$, 相应的负样本表示为 $(h, r, t') \mid t' \in E, t' \neq t$ 。将所有负样本组成完整的负样本集合 T' 。本文使用 TransE 模型, 并将其三元组损失函数最小化作为训练目标。

$$\text{loss} = \sum_{(h, r, t) \in T} \sum_{(h', r, t') \in T'} \max(0, \gamma - f(h, r, t) + f(h', r, t') + \eta \|\theta\|_2^2) \quad (18)$$

其中, loss 表示损失函数值, (h, r, t) 表示三元组, T 表示三元组样本集, (h', r, t') 表示负三元组, T' 表示负三元组样本集, \max 为取最大值函数, γ 表示边距值, $f(h, r, t) = -\|h + r - t\|$ 表示评分函数, $f(h, r, t)$ 表示 (h, r, t) 的评分值, $f(h', r, t')$ 表示 (h', r, t') 的评分值, η 表示超参数, θ 表示所有参数的集合, $\|\theta\|_2^2$ 表示对所有参数进行标准 L_2 正则化, h 表示三元组中的头实体, r 表示关系, t 表示三元组中的尾实体, h' 表示负三元组中的头实体, t' 表示负三元组中的尾实体。

4 实验及分析

本文在两个数据集上进行实验, 并评价 FuDS-KGC, 以验

证融合实体的文本描述和拓扑结构信息的有效性。

4.1 数据集

本文使用的数据集为 FB15k-237 和 WN18RR, 它们是原始数据集 FB15K 和 WN18 的修改版本, 分别来自知识库 FreeBase 和 WordNet。在知识图谱中, 许多三元组可以通过反转关系获得, 从而产生具有相反头实体和尾实体的三元组。例如, 在三元组(张三, 朋友, 李四)中, “李四”的逆关系是“张三”, 即产生了三元组(李四, 朋友, 张三)。数据集 WN18 和 FB15K 包含大量逆关系, 同时允许测试三元组通过逆关系映射到训练三元组。为了解决这个问题, 对应的子集 WN18RR 和 FB15k-237 是通过从 WN18 和 FB15K 中移除逆关系而生成的。表 1 列出了这些数据集的统计信息, “Rel”和“Ent”分别表示数据集中关系和实体的数量, 其他 3 个列分别表示训练数据集、验证数据集和测试数据集。

表 1 实验数据集
Table 1 Experimental datasets

Dataset	Rel	Ent	Train	Valid	Test
FB15k-237	237	12541	272115	17535	20466
WN18RR	11	40493	86845	3034	3134

4.2 实验设置

在实验中, 模型的超参数是通过在验证集上基于实验指标进行网格搜索选择的。选择嵌入维度 d 的范围是 {100, 200, 400, 600}, 学习率的范围是 {0.0001, 0.0005, 0.001}, 最大边缘 γ 的范围是 {3, 6, 9}, batch size 可以从 {32, 64, 128, 256, 512} 中选择, Transformer 编码器中的层数 N 设置为 6。为了加速模型收敛并防止过拟合, 实体嵌入向量和关系嵌入向量使用了来自 TransE 的预训练结果进行初始化。所有实验都是在 NVIDIA GeForce GTX 3080 GPU 上进行的, 并使用 PyTorch 在 Python 中实现。

4.3 评价指标

本文使用两个评价指标来评估模型的性能, 对测试集中的每个三元组的得分进行排名, 并且以排名的高低来评估补全效果的好坏。两个评价指标为: 1) 平均倒数排名 (Mean Reciprocal Rank, MRR), 衡量正确三元组的平均倒数排名; 2) Hits@N, 表示在前 N 个候选三元组 ($N=1, 10$) 中正确三元组所占的比例。一个好的知识图谱补全模型应该表现出较高的 MRR 和 Hits@N。

4.4 对比模型

为了验证 FuDS-KGC 的有效性, 本文从 3 个方面选取对比模型来进行验证: 1) 选取仅依赖于三元组结构信息的模型 (TransE^[12], RoataE^[16], DistMult^[19], ConvE^[23] 和 TuckER^[35]), 以证明融合额外附加信息能够增强实体表征能力; 2) 选取融合实体描述这一附加信息的模型 (EDA-KGC^[32], KG-BERT^[36] 和 StAR^[37]), 以验证融合实体描述信息可以丰富实体的特征表示, 同时验证本文所提方法 FuDS-KGC 的有效性; 3) 选取利用拓扑结构这一附加信息的模型 (CompGCN^[10] 和 DRRGAT^[34]), 以验证实体的拓扑结构能够增强实体的表征能力, 从而进一步验证 FuDS-KGC 的有效性。

TransE 模型^[12]是知识图谱嵌入最经典的方法之一, 它

将关系视为低维向量空间中从头实体到尾实体的平移, 但它的结构过于简单, 难以处理复杂的关系。

RotatE 模型^[16]将关系视为从头实体到尾实体的旋转, 这种方法能有效处理 1-N, N-1, N-N 关系模式。

DistMult 模型^[19]使用向量表示实体和对角矩阵表示关系, 并通过匹配嵌入向量空间中实体和关系的潜在语义来衡量三元组事实的概率。

ConvE 模型^[23]将头实体和关系表示进行整合作为模型输入, 然后通过卷积操作生成多个特征图, 最后将特征图投影到一维向量, 并将其与尾实体进行点积运算得到最终的三元组评分。这种方法在大规模数据集上表现出了较强的竞争力。

EDA-KGC 模型^[32]通过整合实体描述和网络结构来优化实体及关系的表示, 显著提升了性能。该模型包括 3 个核心组件: 1) 表示组件, 通过实体描述进行预训练以获取初始表示; 2) 深度交互组件, 提取实体和关系之间的交互特征; 3) 推理组件, 利用这些特征进行矩阵运算, 快速预测尾实体的概率分布, 从而提高推理效率并增强模型对大规模知识图谱的处理能力。

DRRGAT 模型^[34]提出了一个具有动态关系表示和全局信息的图注意力网络来补全知识图谱, 以动态关系表示学习不同三元组中相同关系的独特表示, 并将全局嵌入机制纳入到图注意力网络, 以获取实体和关系的全局信息。

TuckER 模型^[35]在表示实体和关系时使用多维度嵌入, 能够更好地捕捉实体和关系的多样性特征, 有助于准确地表示知识图谱中的复杂结构和语义信息。但由于参数规模的限制, 这种方法在获取语义信息时效果较差。

KG-BERT 模型^[36]是 BERT 在知识图谱上的首次应用, 它将实体和关系的描述作为输入以获取知识的深层语义信息。

StAR 模型^[37]是一个基于孪生网络结构的预训练语言模型, 它充分利用实体和关系, 并提出了两种评分策略, 来同时对上下文信息和结构信息进行建模。

CompGCN 模型^[10]同时学习节点和关系的表示, 并使用向量来表示节点, 缓解了过度参数化的问题。

4.5 实验结果及分析

本文将 FuDS-KGC 与 TransE 等 10 个对比模型进行比较, 以验证 FuDS-KGC 的性能。表 2 列出了 FuDS-KGC 及其对比模型在 FB15k-237 和 WN18RR 两个数据集上的链接预测评估结果, 其中粗体表示每个指标的最优结果。

表 2 在 FB15k-237 和 WN18RR 上的链接预测结果
Table 2 Link prediction results on FB15k-237 and WN18RR

Models	FB15k-237			WN18RR		
	MRR	Hit@10	Hit@1	MRR	Hit@10	Hit@1
TransE	0.285	0.473	0.190	0.220	0.504	0.406
RotatE	0.338	0.533	0.241	0.476	0.571	0.428
DistMult	0.281	0.446	0.199	0.444	0.504	0.412
ConvE	0.325	0.501	0.237	0.430	0.520	0.400
TuvkER	0.358	0.544	0.266	0.470	0.526	0.440
CompGCN	0.355	0.535	0.264	0.479	0.546	0.443
KG-BERT	—	0.420	—	—	0.524	—
StAR	0.365	0.562	0.266	0.401	0.709	0.243
DRRGAT	0.360	0.549	0.268	0.468	0.579	0.421
EDA-KGC	0.362	0.551	0.270	0.493	0.573	0.452
FuDS-KGC	0.357	0.571	0.273	0.481	0.712	0.246

从表 2 可以看出,在 FB15k-237 数据集上,FuDS-KGC 在 Hits@10 和 Hits@1 指标上取得了最佳的结果。同时,与近两年表现较好的模型 EDA-KGC 相比,FuDS-KGC 在 Hit@10 和 Hit@1 上分别提升了 0.02 和 0.003,说明了 FuDS-KGC 融合多源信息的有效性,能够更深入地捕捉和理解实体间的关系。在 MRR 指标上,FuDS-KGC 模型略差于性能最好的方法,可能是 StAR 比 FuDS-KGC 更好地利用了文本信息,它将每个三元组划分为两个不对称的部分,并通过文本编码器将这两个部分编码为上下文,具有更好的表示学习能力。

在 WN18RR 数据集上,FuDS-KGC 的 Hits@10 高于所有对比模型。但是在 Hits@1 指标上,FuDS-KGC 比目前效果最佳的模型 EDA-KGC 低了 0.206。EDA-KGC 的卓越性能可归因于它通过整合实体描述和网络结构来优化实体及关系的表示,从而在学习表示中有更多的表达能力。此外,可以看到,FuDS-KGC 在 Hit@1 指标上低于所有对比模型,这可能是由于融合学习策略在增广预测范围时,对精确度造成了一定的影响。

4.6 消融实验

本文对 FuDS-KGC 进行消融实验,以验证融合实体的不同附加信息与动态门控融合机制的有效性。FuDS-KGC 的变体如下:1)使用直接拼接的方法代替 FuDS-KGC 中的动态门控融合机制,以融合实体的描述特征表示和拓扑结构特征表示,记为 FuDS-KGC(concat);2)去除 FuDS-KGC 中拓扑结构信息的变体,记为 FuDS-KGC(-Topological);3)去除 FuDS-KGC 中实体文本描述信息的变体,记为 FuDS-KGC(-Text);4)在 FuDS-KGC 中只使用三元组结构信息的变体,记为 FuDS-KGC(-Topological&Text);5)去除了实体描述作为注意力的操作,直接从实体表示集 S_e 中提取特征,并用图注意力网络来获取拓扑结构特征表示的变体,记为 FuDS-KGC(-Text_attention)。FuDS-KGC 及其变体的消融实验结果如表 3 所列。

表 3 消融实验

Table 3 Ablation experiment

Models	Hit@10	
	FB15k-237	WN18RR
FuDS-KGC	0.571	0.712
FuDS-KGC(concat)	0.560	0.701
FuDS-KGC (-Topological)	0.533	0.571
FuDS-KGC (-Text_attention)	0.550	0.653
FuDS-KGC (-Text)	0.504	0.536
FuDS-KGC (-Topological&Text)	0.473	0.504

1)从表 3 中可知,FuDS-KGC 优于它所有的变体,这证明了融合实体的不同附加信息与所设计的动态门控融合机制能有效地提高 FuDS-KGC 在知识图谱补全中的准确性。

2)通过比较 FuDS-KGC(concat)与 FuDS-KGC 的结果可知,所设计的动态门控融合机制在融合实体的描述特征和拓扑结构特征时优于直接拼接方法,原因是动态门控融合机制在训练过程中能自适应融合实体的描述特征和拓扑结构

特征,从而捕获更加丰富的隐藏信息。

3)通过比较 FuDS-KGC(-Topological)与 FuDS-KGC 的结果可知,FuDS-KGC 中的实体拓扑结构表示学习模块在获取实体特征时明显优于直接使用 TransE 模型对三元组自身结构进行预训练的方法,这是因为融合实体拓扑结构信息能进一步补充实体特征表示,从而更加准确地表达实体。

4)从表 3 中可知,FuDS-KGC(-Text)的结果明显低于 FuDS-KGC。其原因是实体的文本描述包含与实体相关的丰富语义特征,FuDS-KGC 中的实体描述表示学习模块能够准确地从文本描述中提取关键的语义特征,从而丰富实体的特征表示。

5)比较 FuDS-KGC(-Topological&Text)与 FuDS-KGC 的结果可知,不借助实体描述和拓扑结构这两种附加信息,仅从三元组自身结构中学习特征表示的补全效果最差。其原因在于,知识图谱中存在长尾分布的问题,当实体数量比较稀疏时,很难捕获到充足的实体特征信息。

6)从表 3 中可知,FuDS-KGC(-Text_attention)的性能(Hit@10 为 0.550 FB15k-237 和 0.653 WN18RR)虽然低于完整的 FuDS-KGC 模型,但仍然显著优于完全不使用文本描述的 FuDS-KGC(-Text)模型(Hit@10 为 0.504 FB15k-237 和 0.536 WN18RR)。这一结果明确说明了实体描述在 FuDS-KGC 中不仅作为一种信息输入,而且其作为注意力机制的一部分在提升拓扑结构信息处理中发挥了关键作用。进一步地,证明了实体描述作为注意力可以帮助 FuDS-KGC 更准确地确定相关实体和关系的语义特征,进而在复杂的关系环境中提供更为精确的信息处理能力。

结束语 本文介绍了一种融合实体描述和拓扑结构的知识图谱补全方法(FuDS-KGC)。FuDS-KGC 中的实体文本描述表示学习模块通过 Transformer 和注意力机制提取实体特定于关系的文本描述特征,解决实体描述表示不准确的问题,从而提升了模型补全的准确性。实体拓扑结构表示学习构建实体的一阶邻居子图,通过图注意力网络获得实体的拓扑结构特征,使得实体针对不同关系有着不同的语义表示,从而丰富实体的特征表示。融合学习模块设计一种动态门控融合机制来融合实体的文本描述特征和拓扑结构特征,增强实体的综合特征表示,解决了现有研究工作融合附加信息单一的问题,在知识图谱补全任务中发挥了关键性作用。在 FB15k-237 和 WN18RR 两个数据集上的实验结果表明,FuDS-KGC 在知识图谱补全任务上具有较好的性能。

尽管 FuDS-KGC 在 FB15k-237 和 WN18RR 两个数据集上的实验验证了其有效性,但该方法仍存在一定的局限性。1)精确度的牺牲:在融合多源信息以扩展预测范围的过程中,FuDS-KGC 在 WN18RR 数据集上的 Hit@1 指标显示出较低的精确度。这表明在增强模型的泛化能力时,可能对单一预测的精确性造成了影响。此结果可能是由于动态门控融合机制在处理不同类型的信息(文本描述和拓扑结构)时,未能充分平衡各类信息的影响权重,导致在某些情况下预测结果的精度不高。2)MRR 指标上的劣势:在 MRR 指标上,FuDS-KGC 在 FB15k-237 数据集上的表现也略差于一些其他模型,如 StAR。这可能指出 FuDS-KGC 在整体排序效果上的

不足,尤其是在整合不同信息源以优化排名时的效率问题。StAR 模型通过更有效地使用文本信息,将三元组分割成不对称的部分来进行处理,可能在这方面做得更好。3)信息源融合的问题:虽然 FuDS-KGC 试图通过融合实体的文本描述和拓扑结构信息来增强特征表示,但模型在某些指标上的表现不佳可能反映了信息融合策略的不完善。特别是实体描述与拓扑结构特征的动态权重分配可能存在偏差,未能达到理想的信息互补效果。4)实验数据集的选择:本文主要在 FB15k-237 和 WN18RR 这两个数据集上进行评估,这可能限制了 FuDS-KGC 在其他类型知识图谱上的适用性和表现。未来研究可能需要在更多种类的数据集上进行测试,以验证模型的广泛适用性和稳定性。

为了克服这些问题,未来工作可以考虑以下几个方向。

1)优化信息融合机制:进一步研究和改进动态门控融合机制,尤其是在权重分配和信息类型平衡方面,以提高 FuDS-KGC 在各个指标上的表现。2)模型细分优化:根据不同的数据集特性,调整 FuDS-KGC 结构和参数,尤其是针对那些需要高精度预测的预测场景。3)扩展实验验证:在更广泛的数据集上测试 FuDS-KGC 的效果,以评估其泛化能力和适应性。

参 考 文 献

- [1] WANG J B, LAI X L, LIN X Y, et al. Context-aware Temporal Knowledge Graph Completion Based on Relation Constraints [J]. *Computer Science*, 2023, 50(3): 23-33.
- [2] KEJRIWAL M, SZEKELY P. Knowledge graphs for social good: An entity-centric search engine for the human trafficking domain [J]. *IEEE Transactions on Big Data*, 2017, 8(3): 592-606.
- [3] PHAN T, DO P. Building a Vietnamese question answering system based on knowledge graph and distributed CNN [J]. *Neural Computing and Applications*, 2021, 33(21): 14887-14907.
- [4] YANG Y, HUANG C, XIA L, et al. Knowledge graph contrastive learning for recommendation [C] // *Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval*. 2022: 1434-1443.
- [5] GUO D, TANG D, DUAN N, et al. Dialog-to-action: conversational question answering over a large-scale knowledge base [C] // *Proceedings of the 32nd International Conference on Neural Information Processing Systems*. 2018: 2946-2955.
- [6] ZHANG T C, TIAN X, SUN X H, et al. Overview on Knowledge Graph Embedding Technology Research [J]. *Ruan Jian Xue Bao/Journal of Software*, 2023, 34(1): 277-311.
- [7] XIE R, LIU Z, JIA J, et al. Representation learning of knowledge graphs with entity descriptions [C] // *Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence*. 2016: 2659-2665.
- [8] XIAO H, HUANG M, MENG L, et al. SSP: semantic space projection for knowledge graph embedding with text descriptions [C] // *Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence*. 2017: 3104-3110.
- [9] XU J, QIU X, CHEN K, et al. Knowledge graph representation with jointly structural and textual encoding [C] // *Proceedings of the 26th International Joint Conference on Artificial Intelligence*. 2017: 1318-1324.
- [10] VASHISHTH S, SANYAL S, NITIN V, et al. Composition-based multi-relational graph convolutional networks [C] // *ICLR 2020*. 2020.
- [11] NATHANI D, CHAUHAN J, SHARMA C, et al. Learning attention-based embeddings for relation prediction in knowledge graphs [C] // *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*. 2019: 4710-4723.
- [12] BORDES A, USUNIER N, GARCIA-DURÁN A, et al. Translating embeddings for modeling multi-relational data [C] // *Proceedings of the 26th International Conference on Neural Information Processing Systems-Volume 2*. 2013: 2787-2795.
- [13] WANG Z, ZHANG J, FENG J, et al. Knowledge graph embedding by translating on hyperplanes [C] // *Proceedings of the Twenty-Eighth AAAI Conference on Artificial Intelligence*. 2014: 1112-1119.
- [14] LIN H, LIU Y, WANG W, et al. Learning Entity and Relation Embeddings for Knowledge Resolution [J]. *Procedia Computer Science*, 2017, 108: 345-354.
- [15] JI G, HE S, XU L, et al. Knowledge graph embedding via dynamic mapping matrix [C] // *Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (volume 1: Long papers)*. 2015: 687-696.
- [16] SUN Z, DENG Z H, NIE J Y, et al. Rotate: Knowledge graph embedding by relational rotation in complex space [J]. *arXiv: 1902.10197*, 2019.
- [17] LI J, SU X. TransERR: Translation-based Knowledge Graph Completion via Efficient Relation Rotation [J]. *arXiv: 2023.14580*, 2023.
- [18] NICKEL M, TRESP V, KRIEGEL H P. A three-way model for collective learning on multi-relational data [C] // *ICML*. 2011: 3104482-3104584.
- [19] YANG B, YIH W, HE X, et al. Embedding entities and relations for learning and inference in knowledge bases [C] // *Proceedings of the International Conference on Learning Representations (ICLR)*. 2015.
- [20] TROUILLON T, DANCE C R, GAUSSIÉ É, et al. Knowledge graph completion via complex tensor factorization [J]. *Journal of Machine Learning Research*, 2017, 18(130): 1-38.
- [21] ZHANG Z, CAI J, WANG J. Duality-induced regularizer for tensor factorization based knowledge graph completion [J]. *Advances in Neural Information Processing Systems*, 2021, 33: 21604-21615.
- [22] CHEN Y H, TAN C Y, CHEN W L, et al. Chinese knowledge Graph Completion with Multiple Embeddings [J]. *Journal of Chinese information processing*, 2023, 37(1): 54-63.
- [23] DETTMERS T, MINERVINI P, STENETORP P, et al. Convolutional 2D knowledge graph embeddings [C] // *Proceedings of the Thirty-Second AAAI Conference on Artificial Intelligence and Thirtieth Innovative Applications of Artificial Intelligence*

- Conference and Eighth AAI Symposium on Educational Advances in Artificial Intelligence. 2018;1811-1818.
- [24] NGUYEN D Q, NGUYEN T D, NGUYEN D Q, et al. A novel embedding model for knowledge base completion based on convolutional neural network[C]//Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. 2018;327-333.
- [25] ZOU C L, AN J M, LI G Y. Knowledge graph entity type completion based on neighborhood aggregation and CNN[J]. Computer Engineering, 2023, 49(3):134-141.
- [26] SOCHER R, CHEN D, MANNING C D, et al. Reasoning with neural tensor networks for knowledge base completion[C]//Proceedings of the 26th International Conference on Neural Information Processing Systems-Volume 1. 2013;926-934.
- [27] WANG Z, ZHANG J, FENG J, et al. Knowledge graph and text jointly embedding[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing(EMNLP). 2014;1591-1601.
- [28] DAI S, LIANG Y, LIU S, et al. Learning entity and relation embeddings with entity description for knowledge graph completion [C]//2018 2nd International Conference on Artificial Intelligence: Technologies and Applications(ICAITA 2018). Atlantis Press, 2018;194-197.
- [29] GU J, WANG Z, KUEN J, et al. Recent advances in convolutional neural networks[J]. Pattern recognition, 2018, 77:354-377.
- [30] ZHONG H, ZHANG J, WANG Z, et al. Aligning knowledge and text embeddings by entity descriptions[C]//Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing. 2015;267-272.
- [31] XIAO H, HUANG M, MENG L, et al. SSP: semantic space projection for knowledge graph embedding with text descriptions [C]//Proceedings of the Thirty-First AAI Conference on Artificial Intelligence. 2017;3104-3110.
- [32] YU C, ZHANG Z, AN L, et al. A knowledge graph completion model integrating entity description and network structure[J]. Aslib Journal of Information Management, 2023, 75(3):500-522.
- [33] SCHLICHTKRULL M, KIPF T N, BLOEM P, et al. Modeling relational data with graph convolutional networks[C]//The Semantic Web;15th International Conference, ESWC 2018, Heraklion, Crete, Greece, June 3-7, 2018, proceedings 15. Springer International Publishing, 2018;593-607.
- [34] ZHANG X, ZHANG C, GUO J, et al. Graph attention network with dynamic representation of relations for knowledge graph completion[J]. Expert Systems with Applications, 2023, 219:119616.
- [35] BALAZEVIC I, ALLEN C, HOSPEDALES T. TUCKER: Tensor Factorization for Knowledge Graph Completion[C]//2019 Conference on Empirical Methods in Natural Language Processing and 9th International Joint Conference on Natural Language Processing. Association for Computational Linguistics, 2019:5184-5193.
- [36] YAO L, MAO C, LUO Y. KG-BERT: BERT for knowledge graph completion[J]. arXiv:1909.03193, 2019.
- [37] WANG B, SHEN T, LONG G, et al. Structure-augmented text representation learning for efficient knowledge graph completion [C]//Proceedings of the Web Conference 2021. 2021:1737-1748.



HAN Daojun, born in 1979, Ph.D, professor, is a member of CCF (No. 28531S). His main research interests include information security, block-chain, and knowledge graph.



ZHANG Juntao, born in 1989, Ph.D, lecturer, is a member of CCF (No. A1199M). His main research interests include data mining, knowledge graph, big data management and analysis, and fairness.

(责任编辑:喻黎)