山西大学学报(自然科学版)49(4):571—580,2026
Journal of Shanxi University(Nat. Sci. Ed.)

DOI:10.13451/j.sxu.ns.2025116

面向少样本知识图谱补全的关系感知语义建模方法

胡杨娟,汪凯乐,杨飞,李玉玲*
(安徽医科大学 生物医学工程学院,安徽 合肥 230012)

摘 要:近年来,少样本知识图谱补全任务因能通过少量参考三元组推理目标关系下的未知查询而备受关注。本文提出一种关系感知语义建模方法,通过联合建模三元组的图结构上下文与局部邻居语义,实现关系语义与实体语义的深度融合。该方法首先利用上下文路径生成器提取覆盖多跳依赖的图结构信息,再借助多尺度图表示编码器分别建模全局结构化语义与局部邻域语义,最终通过语义匹配聚合模块完成查询三元组与支持三元组的关系特定比对。在两个基准数据集NELL-One与Wiki-One上进行的实验表明,该方法在多个主流评估指标上均优于现有代表性方法。以NELL-One数据集为例,平均倒数排名、命中率前十、前五和前一指标分别提升3.8%、2.4%、2.2%和4.3%,验证了该方法在应对实体邻居稀疏与多重关系语义混淆问题时具备良好的表示能力与鲁棒性。

关键词:少样本知识图谱补全;上下文建模;多尺度表示学习;关系语义表示
中图分类号:TP391 **文献标志码**:A **文章编号**:0253-2395(2026)04-0571-10

Relation-aware Semantic Modeling Approach for Few-shot Knowledge Graph Completion

Hu Yangjuan, Wang Kaile, Yang Fei, Li Yuling*
(*School of Biomedical Engineering, Anhui Medical University, Hefei* 230012*, China*)

Abstract: Few-shot knowledge graph completion aims to infer unseen queries for a target relation with only a few support triples. This study proposed a relation-aware semantic modeling method. It integrated global structural context and local neighborhood semantics of triples to create expressive relation-specific representations. The method used a context path generator to extract multi-hop dependency paths. It also employed a multi-scale graph encoder to capture global semantic structure and local entity features. A semantic matching aggregation module aligned query triples with support triples under each relation. Experiments on NELL-One and Wiki-One datasets showed consistent improvement over existing methods on multiple metrics. For the five-shot setting on NELL-One, it increased mean reciprocal rank, Hits@10, Hits@5, and Hits@1 by 3.8%, 2.4%, 2.2%, and 4.3%, respectively. The results demonstrate the method's effectiveness and robustness in handling sparse neighborhoods and relation ambiguity in few-shot scenarios.

Key words: few-shot knowledge graph completion; context modeling; multi-scale representation learning; relation semantic representation

收稿日期:2025-09-15;**修回日期**:2025-11-17
基金项目:国家自然科学基金(62406007;62401016)
作者简介:胡杨娟(2001—),女,安徽安庆人,硕士研究生,研究方向为自然语言处理。E-mail:2345012550@stu.ahmu.edu.cn
* **通信作者**:李玉玲(Li Yuling),E-mail: liyuling@ahmu.edu.cn
引文格式:胡杨娟,汪凯乐,杨飞,等.面向少样本知识图谱补全的关系感知语义建模方法[J].山西大学学报(自然科学版),2026,49(4):571-580. DOI:10.13451/j.sxu.ns.2025116.

0 引言

知识图谱本质上是由海量事实构成的多关系网络,其基本单位为三元组(头实体,关系,尾实体),记为。例如,三元组(爱因斯坦,出生地,德国)表明“爱因斯坦的出生地是德国”。当前,以YAGO(Yet Another Great Ontology)[1]、NELL(Never-ending Language Learner)[2]和Wikidata[3]为代表的大规模知识图谱,已在问答系统[4]、语义搜索[5]、信息抽取[6]等下游任务中广泛应用。尽管知识图谱规模庞大,但其构建依赖有限文本导致事实覆盖不全,需通过知识图谱补全推断新三元组。

传统知识图谱嵌入(Knowledge Graph Embedding, KGE)方法通过学习实体与关系的低维向量表示以辅助三元组预测,在全监督场景中取得了良好效果[7-8]。然而,在真实知识图谱中,许多关系仅含极少数对应三元组,例如Wikidata中超过10%的关系仅包含不超过10条三元组[9]。此外,新增关系往往样本不足,导致KGE方法在少样本场景下性能下降。现有的少样本知识图谱补全(Few-shot Knowledge Graph Completion, FKGC)方法存在两大局限:一是过度依赖一跳邻居,难以应对长尾实体的稀疏性问题。例如部分现有方法仅利用实体的直接邻居进行表示学习,当实体邻居稀少或缺失时(如罕见病实体“戈谢病”),其表示能力严重受限,易导致语义混淆;二是忽略多跳关系路径,导致关系表示缺乏上下文感知。多数方法仅通过头尾实体对生成关系表示,未能利用多跳路径中蕴含的丰富语义信息。这使得模型难以区分语义相近但路径依赖不同的关系,限制了推理精度。

为应对上述挑战,本文提出一种关系感知语义建模方法(Relation-aware Semantic Modeling, RASM),用于少样本场景下的知识图谱补全。该方法基于上下文路径生成器构建包含一跳与多跳关系的结构化图上下文,进而捕捉跨跳语义路径信息。随后,引入多尺度图表示编码器,融合基于Transformer的结构化语义编码器和基于图神经网络的邻域感知编码器,联合建模全局路径与局部邻域特征,生成三元组语义表示;最终,通过语义匹配聚合模块对查询与支持三元组进行匹配评分,实现对少样本关系的有效补全[10-12]。与传统FKGC方法相比,RASM弱化了对直接邻居和实体对表示的依赖,提升了长尾实体的区分能力,并增强了对多关系语义路径的建模能力。

本文的主要贡献可概括为以下三个方面:

1)提出一种面向少样本关系的上下文感知建模框架,通过建模图结构上下文信息,生成融合关系语义与实体语义的关系特定表示。

2)设计多尺度图表示编码器,融合Transformer与图神经网络的结构优势,以精准捕获全局跨跳路径与局部关键邻域特征。

3)在两个公开基准数据集NELL-One与Wiki-One上开展了充分实验,结果表明所提方法在多个评估指标上全面超越现有最优模型,并通过消融实验验证了核心模块的有效性与必要性。

1 相关工作

1.1 传统知识图谱补全

知识图谱补全(Knowledge Graph Completion, KGC)任务的目标是解决知识图谱的不完备性,通过已有三元组推断新三元组。一种主流的KGC方法是将实体和关系嵌入低维分布式向量空间中,并设计评分函数评估三元组的合理性。现有的知识图谱嵌入方法主要分为平移模型和语义匹配模型这两大类。

平移模型将关系解释为实体对之间的几何平移操作,并构建基于距离的评分函数。TransE(Translating Embeddings)[6]作为该领域的开创性工作,将关系建模为连接头尾实体的平移向量,实现了高效知识表示,但其难以处理一对多、多对一等复杂关系模式。为此,TransH(Translation on Hyperplanes)[13]通过引入关系特定超平面,使实体在不同关系下具备差异化表示。TransR(Translation in Relation Space)[14]进一步采用实体空间与关系空间分离的矩阵投影机制,提升了对多语义实体和复杂关系的建模能力。

语义匹配模型通过计算实体与关系的语义相似度,对三元组的合理性进行评分。RESCAL(Tensor-based Relational Learning Approach

Capable of Collective Learning)[15]采用张量分解方法,通过关系矩阵建模实体间的成对交互;DistMult(Distributed Multiple)[16]对RESCAL进行简化,将关系矩阵约束为对角矩阵以提升效率,但过度简化使其无法处理非对称关系;ComplEx(Complex Embeddings)[7]则创新性地引入复数空间表示,在保持效率的同时有效建模了对称与非对称关系。近年来,如多层感知机[17]、卷积神经网络[18-19]和图神经网络[20]等神经网络模型通过复杂架构进一步提升了语义匹配能力。SIM(Semantic Interaction Matching)[21]通过使用Transformer框架捕捉实体邻居间的语义交互以增强表示,并利用注意力机制计算语义匹配得分,显著提升性能。

尽管这些传统KGC模型效果显著,但其通常假设所有关系均具备充足的训练三元组。相比之下,本研究聚焦于少样本场景下的KGC任务。例如,目前针对罕见遗传病如"戈谢病(Gaucher disease)"的医学研究样本严重不足,而本模型仅需有限训练数据即可高效补全该疾病的知识图谱。这一能力对推动罕见病研究进程、辅助诊断[22]等下游信息检索任务具有重要意义。

1.2 少样本知识图谱补全

少样本知识图谱补全方法可分为基于元度量学习的方法和基于元优的方法[23]。

1)基于元度量学习的方法:GMatching[11]作为首个FKGC研究,利用邻居编码器融合直接邻居信息学习实体表示;FSRL(Few-shot Relation Learning Model)[24]将其进一步深化,引入注意力机制对直接邻居进行差异化权重编码;FAAN(Adaptive Attentional Network for Few-Shot KG completion)[12]提出实体表示应具备关系自适应性,学习动态属性表示;FCC(Few-shot Knowledge Graph Completion Framework Through Complementary Diverse Feature Learning and Consistent Relation Modeling)[25]通过双分支特征提取器获取互补实体表示,并引入结构关系建模,解决了FKGC中的关系表示不一致问题。

2)基于元学习的方法:MetaR(Meta Relational Learning)[9]通过关系元学习器从实体对嵌入中生成关系元信息,实现新关系的快速梯度更新学习;GANA-MTransH(Gated and Attentive Neighbor Aggregator with Meta-learning-based TransH)[26]沿袭相似思路,但通过关系特定超平面参数建模复杂关系;SMetaR(Simple and Effective Meta Relational Learning Model)[27]采用基于线性模型的元关系学习器和TransH翻译模型,有效保留少样本关系特征并处理复杂关系。

本研究与现有FKGC方法的差异主要有两点:一是现有方法依赖头尾实体的局部邻域,难以应对长尾实体邻居稀疏问题;而本方法通过编码语境化信息,同步学习全局感知与局部感知的三元组表示。二是现有方法依赖头尾实体语义生成关系表示,而本方法融合头实体、关系及尾实体的联合表示,构建更具判别力的关系特定表征。

2 关系感知语义建模技术

本节介绍本文提出的关系感知语义建模框架RASM,其整体结构如图1所示。接下来我们详细阐述了上述各模块的具体设计与实现。

2.1 上下文路径生成器

为获取三元组结构化语境信息,本文提出上下文路径生成器,用于从背景知识图谱$\mathcal{G}$中构建融合头尾实体直接邻居与远距离实体关系对的上下文路径集合。上下文路径生成器的核心思想是围绕目标三元组(h, r, t)构建对应的图上下文,以捕捉局部结构与跨跳语义依赖。给定三元组(h, r, t),其上下文表示路径为$\mathcal{C}(h,t)=\mathcal{P}_{\text{in}}(h)\cup\mathcal{P}_{\text{out}}(t)$。其中,$\mathcal{P}_{\text{in}}(h)$表示头实体$h$的入度路径集合,$\mathcal{P}_{\text{out}}(t)$表示尾实体$t$的出度路径集合,两者共同组成目标三元组的结构化图上下文$\mathcal{C}(h,t)$。

1)头实体的入度路径构建:

首先提取头实体的一阶入度实体关系对$\mathcal{N}_{\text{in}}^{(1)}(h)$:

$$\mathcal{N}_{\text{in}}^{(1)}(h)=\{(e_i,r_i)|(e_i,r_i,h)\in\mathcal{G}\},\qquad(1)$$

其中e_i表示与h相连的实体,r_i表示连接实体对的关系类型。若存在多重关系,则遍历所有的有效(e_i,r_i)对。

其次提取二阶入度实体关系对$\mathcal{N}_{\text{in}}^{(2)}(h)$,构成远邻路径:

$$\mathcal{N}_{\text{in}}^{(2)}(h)=\left\{\begin{matrix}(e_j,r_j)\big|(e_j,r_j,e_i)\in \text{G},\\(e_i,r_i)\in\mathcal{N}_{\text{in}}^{(1)}(h)\end{matrix}\right\},\tag{2}$$

其中e_j表示二阶邻接实体,r_i表示二阶关系类型。

最终构建头实体的入度路径集合$\mathcal{P}_{\text{in}}(h)$:

$$\mathcal{P}_{\text{in}}(h)=\text{Sample}_k\left(\mathcal{N}_{\text{in}}^{(1)}(h)\right)\cup \text{Sample}_m\left(\mathcal{N}_{\text{in}}^{(2)}(h)\right),\tag{3}$$

其中$\text{Sample}_k(\cdot)$表示从一阶邻居中随机采样k个实体关系对,$\text{Sample}_m(\cdot)$表示从二阶邻居中随机采样m个。该机制通过邻域采样控制上下文规模,避免冗余路径带来的干扰。

在训练阶段采用随机采样,其核心优势在于简单、高效且具有随机正则化效应,可以一定程度上增强模型的鲁棒性,避免对某些特定路径的过拟合。

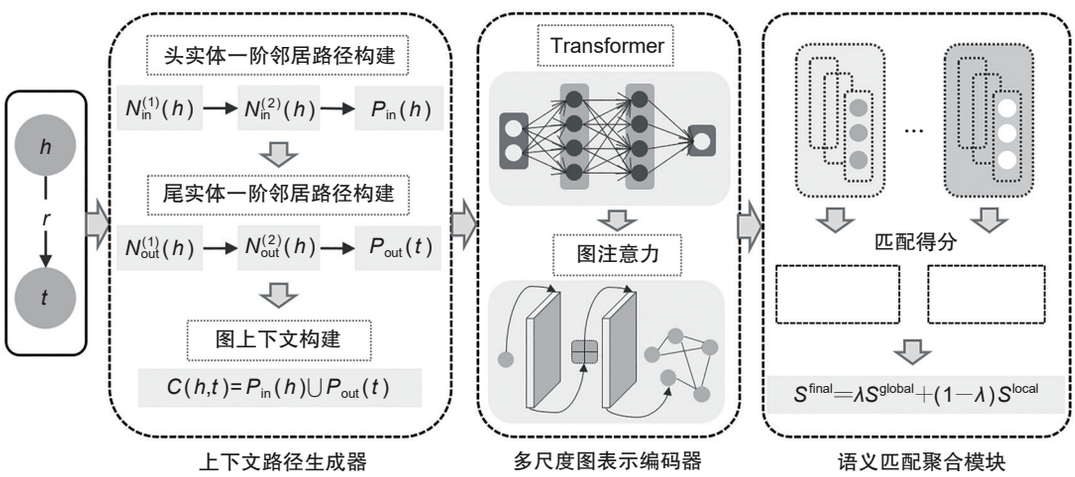


图1 关系感知语义建模框架图

Fig. 1 Framework of the relation-aware semantic modeling approach

2)尾实体的出度路径构建:

对于尾实体的出度路径构建我们采取类似的流程,首先提取尾实体的一阶出度实体关系对$\mathcal{N}_{\text{out}}^{(1)}(t)$:

$$\mathcal{N}_{\text{out}}^{(1)}(t)=\{(r_i,e_i)|(t,r_i,e_i)\in\mathcal{G}\}。\tag{4}$$

其次提取二阶出度实体关系对$\mathcal{N}_{\text{out}}^{(2)}(t)$,构成远邻路径:

$$\mathcal{N}_{\text{out}}^{(2)}(t)=\left\{\begin{matrix}(r_j,e_j)\big|(e_i,r_j,e_j)\in \text{G},\\(r_i,e_i)\in\mathcal{N}_{\text{out}}^{(1)}(t)\end{matrix}\right\}。\tag{5}$$

最后构建尾实体的出度路径集合:

$$\mathcal{P}_{\text{out}}(t)=\text{Sample}_k\left(\mathcal{N}_{\text{out}}^{(1)}(t)\right)\cup \text{Sample}_m\left(\mathcal{N}_{\text{out}}^{(2)}(t)\right)。\tag{6}$$

3)最终图上下文构建:

将头尾实体的路径合并后,构建三元组的上下文图结构$\mathcal{C}(h,t)$:

$$\text{C}(h,t)=\mathcal{P}_{\text{in}}(h)\cup\mathcal{P}_{\text{out}}(t)。\tag{7}$$

为保证上下文路径长度一致,设置路径最大长度为L,若采样结果不足,则采用特殊占位符[PAD]进行填充。训练阶段路径采样为随机方式,而在元测试与验证阶段,使用得分前k的高置信度邻居,提升稳定性与鲁棒性。

2.2 多尺度图表示编码器

为充分建模三元组的结构化图上下文,本文提出多尺度图表示编码器,用于融合全局路径语义与局部邻居信息,生成具有上下文感知能力的三元组表示。该编码器由两个子模块组成:结构化语义编码器与邻域感知编码器。

1)结构化语义编码器:

结构化语义编码器采用Transformer架构,建模实体关系对中的跨跳依赖。首先,将图上下文$\mathcal{C}(h,t)$展开为实体关系序列,为每个元素构建嵌入表示:

$$\boldsymbol{x}_i=\boldsymbol{e}_i+\boldsymbol{p}_i,\tag{8}$$

其中$\boldsymbol{e}_i$表示第i个元素的实体或关系嵌入,$\boldsymbol{p}_i$尾其位置嵌入。

嵌入序列输入L层Transformer块后,得到最终隐藏表示$\{\boldsymbol{h}_i\}$。对所有与目标三元组对应位置的元素表示进行平均池化,构建其全局表示:

$$z^{\text{global}}=\text{MeanPooling}\left(\boldsymbol{h}_{\text{target}}\right)。\tag{9}$$

该编码器能够提取全局语义信息,建模远距离节点之间的依赖,有助于捕捉潜在的语境特征。

2)邻域感知编码器:

邻域感知编码器采用图注意力机制来增强实体在局部邻域内的交互表达。对于头实体h与尾实体t的一阶邻居集合,分别记为$\mathcal{N}(h)$和$\mathcal{N}(t)$,对每个邻居节点e_j与目标实体之间计算注意力权重:

$$\alpha_{hj}=\frac{\exp\left(\mu_j\right)}{\sum_{e_k\in\mathcal{N}(h)}\exp\left(\mu_k\right)},\tag{10}$$

$$\mu_j=\text{LeakyReLU}\left(\boldsymbol{a}^{\top}\left[z_h^{\text{global}}/\!/\boldsymbol{z}_j\right]\right),\tag{11}$$

$$\mu_k=\text{LeakyReLU}\left(\boldsymbol{a}^{\top}\left[z_h^{\text{global}}/\!/\boldsymbol{z}_k\right]\right),\tag{12}$$

其中$\boldsymbol{z}_j$表示邻居e_j的嵌入,z_h^{global}为结构化编码器输出的头实体表示,$\boldsymbol{a}$为可学习的注意力权重向量,$[\cdot/\!/\cdot]$表示向量拼接操作。

加权聚合邻居信息后与远实体表示融合,更新实体语义表示:

$$\tilde{\boldsymbol{z}}_h=\sigma\left(\boldsymbol{W}_1\boldsymbol{z}_h^{\text{global}}+\boldsymbol{W}_2\sum_{e_j\in\mathcal{N}(h)}\alpha_{hj}\boldsymbol{z}_j\right),\tag{13}$$

其中$\boldsymbol{W}_1$、$\boldsymbol{W}_2$为可训练的投影矩阵,$\sigma(\cdot)$表示非线性激活函数(如ReLU)。

同理可得尾实体的增强表示$\tilde{\boldsymbol{z}}_t$。最终经层归一化后生成局部感知三元组表示$\tilde{\boldsymbol{z}}_h$:

$$\tilde{\boldsymbol{z}}_h=\sigma\left(\boldsymbol{W}_1\boldsymbol{z}_t^{\text{global}}+\boldsymbol{W}_2\sum_{e_j\in\mathcal{N}(t)}\alpha_{tj}\boldsymbol{z}_j\right)。\tag{14}$$

该过程使模型能聚焦与实体语义相关的邻居信息,抑制冗余干扰,提高局部感知表示的判别能力。

2.3 语义匹配聚合模块

为提升查询三元组的判别能力,本文设计了语义匹配聚合模块,对支持集中参考三元组表示进行加权整合,学习全局与局部的关系语义。该模块通过注意力机制动态分配权重,使语义接近的参考样本贡献更大,提升匹配鲁棒性。

具体而言,假设支持集中的每个参考三元组经编码后,分别得到其全局表示z_i^{global}与局部表示z_j^{global},查询三元组表示为$z^{\text{query}}=\left[z_{\text{h}}^{\text{global}}\|r\|z_{\text{t}}^{\text{global}}\right]$。我们首先计算查询与参考三元组之间的全局相似度注意力权重:

$$\alpha_i^{\text{global}}=\frac{\exp\left(z_i^{\text{global}}\cdot z^{\text{query}}\right)}{\sum_j\exp\left(z_j^{\text{global}}\cdot z^{\text{query}}\right)}。\tag{15}$$

然后聚合所有参考全局表示,得到全局关系原型:

$$\boldsymbol{r}^{\text{global}}=\sum_i\alpha_i^{\text{global}}\cdot\boldsymbol{z}_i^{\text{global}}。\tag{16}$$

采用相同方式,可计算局部注意力权重与局部关系原型:

$$\alpha_i^{\text{local}}=\frac{\exp\left(z_i^{\text{local}}\cdot z^{\text{query}}\right)}{\sum_j\exp\left(z_j^{\text{local}}\cdot z^{\text{query}}\right)},\tag{17}$$

$$\boldsymbol{r}^{\text{local}}=\sum_i\alpha_i^{\text{local}}\cdot\boldsymbol{z}。\tag{18}$$

接着,分别计算查询三元组与两个原型的匹配得分:

$$S^{\text{global}}=\cos\left(z^{\text{query}},\boldsymbol{r}^{\text{global}}\right),\tag{19}$$

$$S^{\text{local}}=\cos\left(z^{\text{query}},\boldsymbol{r}^{\text{local}}\right)。\tag{20}$$

最终综合得分通过加权融合得到:

$$S^{\text{final}}=\lambda S^{\text{global}}+(1-\lambda)S^{\text{local}},\tag{21}$$

其中$\lambda\in[0,1]$为全局匹配得分与局部匹配得分的权重超参数,控制两种表示对最终预测的贡献。当$\lambda=1$时,仅基于全局信息进行匹配;当$\lambda=0$时,仅基于局部交互特征进行匹配。

2.4 损失函数和模型训练

为优化模型对少样本关系下三元组的判别能力,本文设计了两项互补的目标函数:排序损失函数与掩码重建损失函数。前者用于提升正负三元组之间的区分性,后者用于增强路径结构建模能力。两者联合训练,共同优化模型参数。

1)排序损失函数:

查询三元组(h,r,t)的匹配得分记为$\text{S}(h,r,t)$,通过替换尾实体构造负样本三元组(h,r,t'),其匹配得分为$S(h,r,t')$。为确保正样本得分高于负样本,本文引入基于最大边界的排序损失:

$$\mathcal{L}_{\text{rank}}=\max\left(0,\gamma+S(h,r,t')-S(h,r,t)\right),\tag{22}$$

其中$\gamma>0$表示正负样本得分之间的最小间隔,用于控制模型对错误样本的容忍度。

2)掩码重建损失函数:

设路径最大长度为L,掩盖位置真实标签为

$\{y_i\}$,预测概率为$\{p_i\}$,则定义掩码重建损失如下:

$$\mathcal{L}_{\text{mask}}=-\sum_{i=1}^{L}y_i\log p_i。\tag{23}$$

该损失鼓励模型对实体和关系形成准确建模,从而提升对上下文依赖结构的感知能力。

3)联合训练目标:

最终,RASM模型以排序损失与掩码损失的加权组合作为整体训练目标函数,形式如下:

$$\mathcal{L}_{\text{total}}=\mathcal{L}_{\text{rank}}+\mathcal{L}_{\text{mask}}。\tag{24}$$

训练中采用Adam优化器对全局参数集合进行反向传播更新,并在元验证集上动态调整学习率和训练步数,以提升泛化性能与收敛速度。

3 实验

3.1 数据集

本实验选用FKGC领域广泛使用的两个数据集:NELL-One[28]和Wiki-One[10]。遵循基准研究设定[9,24],数据集按关系划分训练集、测试集和验证集:NELL-One划分为51/11/5,Wiki-One划分为133/34/16。表1汇总了数据集部分统计信息。

3.2 实验设置

所有实验均基于PyTorch框架完成,运行环境为两块NVIDIA GeForce RTX 3090 GPU。为保证对比公平性,本文遵循GMatching[11]的设置方案。上下文路径采样阶段,设一阶邻居上限为$p=8$,二阶邻居上限为$q=5$,上下文聚合阶段中全局与局部匹配的融合系数设置为$\lambda=0.4$,排序损失函数的最小边界间隔设置为$\gamma=5.0$。评估指标方面,采用平均倒数排名(Mean Reciprocal Rank, MRR)和命中率(Hits@N, N=1,5,10)衡量模型性能。其中,MRR反映整体排序能力,Hits@1表示精确预测率,Hits@5与Hits@10分别代表中等与宽松排名下的召回性能。此外,为系统评估模型在资源极度匮乏与适度可用条件下的表现,本文设定5-shot少样本任务模式。

表1 NELL-One和Wiki-One数据集信息统计

Table 1 Statistics of the NELL-One and Wiki-One datasets

数据集	$\lvert\varepsilon\rvert$	$\lvert\mathcal{R}\rvert$
NELL-One	68 545	358
Wiki-One	4 838 244	822

3.3 RASM模型性能分析

为了验证RASM模型的有效性,本文选取了FSRL、FAAN、GANA等12个经典模型与其比较,具体实验结果如表2所示。

表2 各方法在NELL-One和Wiki-One数据集上基于5-shot参考的评估结果

Table 2 Evaluation results of various methods on the NELL-One and Wiki-One datasets under the 5-shot setting

	NELL-One				Wiki-One			
	MRR	Hits@10	Hits@5	Hits@1	MRR	Hits@10	Hits@5	Hits@1
TransE[6]	0.174	0.313	0.204	0.083	0.083	0.117	0.075	0.052
TransH[13]	0.159	0.298	0.183	0.084	0.111	0.159	0.114	0.069
TransR[14]	0.164	0.333	0.183	0.083	0.074	0.132	0.085	0.061
RESCAL[15]	0.187	0.341	0.211	0.108	0.103	0.159	0.116	0.086
DisMult[18]	0.200	0.311	0.251	0.137	0.097	0.161	0.119	0.044
ComplEx[7]	0.184	0.297	0.229	0.118	0.100	0.162	0.122	0.052
GMatching[11]	0.201	0.311	0.264	0.143	0.263	0.387	0.337	0.197
MetaR(In-Train)[9]	0.261	0.437	0.350	0.168	0.211	0.302	0.264	0.178
MetaR(Pre-Train)[9]	0.209	0.355	0.280	0.141	0.323	0.418	0.385	0.270
FSRL[26]	0.184	0.272	0.234	0.136	0.158	0.287	0.206	0.097
FAAN[12]	0.279	0.428	0.364	0.200	0.341	0.436	0.395	0.281
GANA[26]	0.294	**0.472**	0.366	0.177	0.283	0.390	0.339	0.283
RASM	**0.317**	0.452	**0.386**	**0.243**	**0.348**	**0.454**	**0.397**	**0.289**

注:加粗表示最佳结果。

在综合实验结果中,RASM模型在多个评价维度上展现出显著优势,结果表明:

1)在NELL-One和Wiki-One两个数据集上,RASM模型整体性能显著优于所有传统的

KGE方法,充分验证了其在低资源场景下对结构与语义信息建模的有效性与鲁棒性。

2)相较于现有的FKGC基线方法,RASM同样表现出更强的性能优势。以NELL-One数据集为例,RASM相较于表现较优的FAAN模型,在MRR、Hits@10、Hits@5和Hits@1四项指标上分别实现了3.8%、2.4%、2.2%和4.3%的相对性能提升,表明融合图结构上下文有助于增强三元组语义判别能力。

3)与未显式引入邻接结构的MetaR相比,RASM在NELL-One上表现更优,在Wiki-One上也与最优基线表现相当。同时,MetaR跨数据集性能波动较大,而RASM在两个数据集上均表现稳定,展现出更强的泛化能力。

4)对比图注意力网络方法GANA,RASM在Wiki-One的各项指标上全面领先,并在NELL-One的MRR、Hits@5和Hits@1上也表现更佳。这表明RASM通过引入结构上下文与多尺度语义信息,在关系稀疏、实体分布广泛的图谱中展现出更强优势。

3.4 消融实验分析

本实验为评估RASM各模块对整体性能的贡献,本文在NELL-One数据集的5-shot链接预测任务下开展了消融实验。RASM包含两大关键机制:一是通过上下文路径生成器构建结构化图上下文,显式建模跨跳语义;二是引入多尺度图表示编码器,联合建模全局路径与局部邻居信息。为验证两者的独立性与协同效果,本文对远距离路径和编码器结构进行了有针对性的模块裁剪,实验结果如表3所示。

1)为验证图上下文建模的有效性,本文移除路径中的远距离邻居(w/o D-Nei),仅保留一阶实体信息。结果显示,模型性能明显下降,说明跨跳路径在少样本场景下对语义增强具有关键作用。

2)为评估多尺度编码结构的作用,进一步分别移除结构化语义编码器(w/o G-Enc)与邻域感知编码器(w/o L-Enc)。结果显示,两类编码器均为必要组成,说明全局与局部语义建模在少样本三元组表示中具有互补性。

表3 NELL-One数据集上不同模块的消融实验研究

Table 3 Ablation study on different modules of RASM on the NELL-One dataset

消融实验	MRR	Hits@10
w/o D-Nei	0.284	0.416
w/o G-Enc	0.207	0.361
w/o L-Enc	0.261	0.389
Full model	**0.317**	**0.452**

3.5 参数分析

本实验为分析结构化语义编码器与邻域感知编码器在模型训练过程中的相对贡献,本文对其融合权重参数λ(见公式(21))进行了深入实验探究。参数$\lambda=1.0$表示完全采用结构化语义编码器输出,而$\lambda=0$则表示仅使用邻域感知编码器输出。如图2(a)所示,当$\lambda=0.4$时,模型在Wiki-One数据集上取得最优MMR,说明结构化语义与邻域感知需协同建模,方能发挥最大效果。同时,$\lambda=1.0$所对应的MRR显著优于$\lambda=0$,表明相比邻居信息,三元组的图上下文对少样本关系建模具有更关键的作用。

进一步观察图2(b)中的训练曲线可见,训练初期$\lambda=1.0$的模型性能一度低于$\lambda=0$,主要因为远距离邻居尚未充分建模,易引入噪声。随着训练的推进,模型逐步收敛,注意力机制能够有效筛选高置信度路径,最终使得完全依赖图上下文的模型反超仅使用邻域感知的设置,验证了编码器对远距离噪声的鲁棒性。

3.6 时间复杂度分析

3.6.1 训练时间分析

为评估RASM在大规模知识图谱上的扩展能力,本文分析了其训练与推理效率。如表4所示,在不同批次设置下,尽管Wiki-One在规模上远大于NELL-One,但训练耗时差异不大,表明模型具备良好的扩展性与训练效率。

表4 RASM在NELL-One和Wiki-One上的训练时间

Table 4 Training time of RASM on NELL-One and Wiki-One

批量大小	32	64	128	256
NELL-One	5 h	8 h	13 h	23 h
Wiki-One	5 h	8 h	—	—

注:—表示该数据集没有用这个批量大小。

3.6.2 推理时间分析

为评估推理阶段的响应能力,图3展示了

候选实体数量变化下模型的预测时间。结果表明,推理时间随候选数量线性增长,符合匹配机制的计算特性,说明模型在大规模实体空间下具备良好实时性。此外,NELL-One上的平均推理时间略高,可能因其实体邻居更多,导致上下文构建与编码耗时增加。

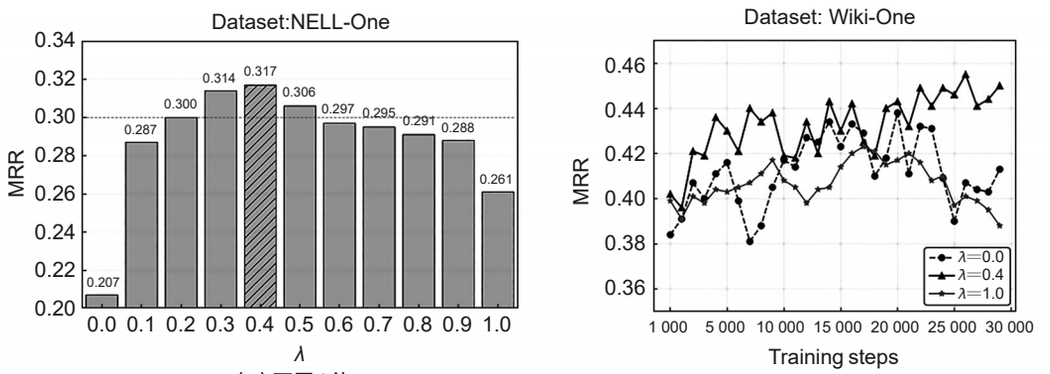


图2 不同数据集使用测试集的RASM学习过程图示

Fig. 2 Learning processes of RASM on the test sets of different datasets

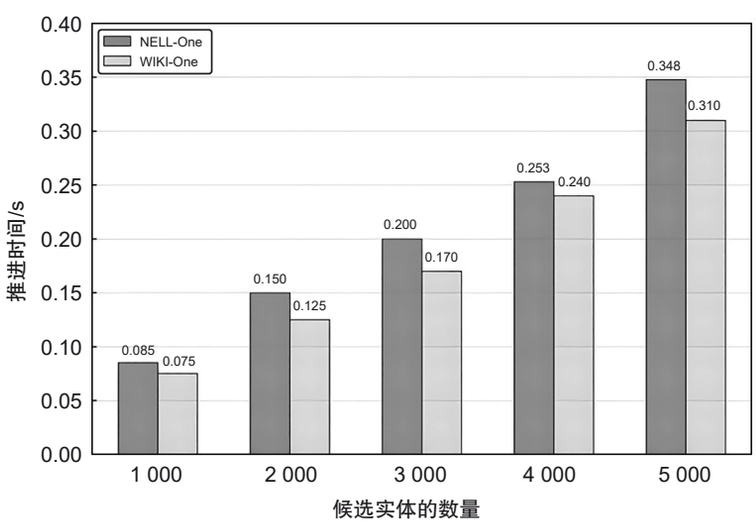


图3 RASM在不同数量候选实体上的推理时间

Fig. 3 Inference time of RASM with different numbers of candidate entities

4 总结与展望

本文提出了一种用于少样本知识图谱补全的关系感知语义建模方法RASM。与仅基于头尾实体及其直接邻居进行关系建模的传统方法不同,RASM构建融合全局图结构与局部语义的上下文路径,通过联合学习策略生成每个少样本关系的关系特定表示。该方法不仅能够捕捉跨跳路径中的丰富语义关联,还保留了实体邻接结构中的有价值信息,从而在表达能力与泛化能力之间取得更优平衡。

在NELL-One与Wiki-One两个数据集上的实验表明,RASM在各项指标上均优于现有主流FKGC方法。消融实验和案例分析进一步验证了多尺度图表示结构,特别是结构化语义编码器与邻域感知编码器的有效性。后续将探索少样本关系与长尾实体的协同建模,并引入实体和关系的文本信息以增强表示能力。此外,还将系统性地研究模型规模、路径采样策略等超参数对性能与效率的量化影响,以提供更全面的工程实践指导。

参考文献:

[1] Suchanek F M, Kasneci G, Weikum G. Yago: A Core of Semantic Knowledge[C]//Proceedings of the 16th International Conference on World Wide Web. New York: ACM,

2007: 697−706. DOI: 10.1145/1242572.1242667.

[2] Carlson A, Betteridge J, Kisiel B, *et al*. Toward an Architecture for Never-ending Language Learning[J]. *Proc AAAI Conf Artif Intell*, 2010, **24**(1): 1306−1313. DOI: 10.1609/aaai.v24i1.7519.

[3] Vrandečić D, Krötzsch M. Wikidata[J]. *Commun ACM*, 2014, **57**(10): 78−85. DOI: 10.1145/2629489.

[4] Singhal K, Tu T, Gottweis J, *et al*. Toward Expert-level Medical Question Answering with Large Language Models[J]. *Nat Med*, 2025, **31**(3): 943−950. DOI: 10.1038/s41591-024-03423-7.

[5] Xiong C Y, Power R, Callan J. Explicit Semantic Ranking for Academic Search *via* Knowledge Graph Embedding[C]// Proceedings of the 26th International Conference on World Wide Web. International World Wide Web Conferences Steering Committee. Geneva: IW3C2. 2017: 1271−1279. DOI: 10.1145/3038912.3052558.

[6] Bordes A, Usunier N, Garcia-duran A, *et al*. Translating Embeddings for Modeling Multi-relational Data[C]//Proceedings of the 27th International Conference on Neural Information Processing Systems, Red Hook: Curran Associates, Inc. 2013, 2787−2795.

[7] Trouillon T, Welbl J, Riedel S, *et al*. Complex Embeddings for Simple Link Prediction[PP/OL]. (2016-06-20)[2025-08-05]. https://arxiv.org/abs/1606.06357.

[8] Zhang W, Paudel B, Wang L, *et al*. Iteratively Learning Embeddings and Rules for Knowledge Graph Reasoning [C]//The World Wide Web Conference. New York: ACM, 2019: 2366−2377. DOI: 10.1145/3308558.3313612.

[9] Chen M Y, Zhang W, Zhang W, *et al*. Meta Relational Learning for Few-shot Link Prediction in Knowledge Graphs[C]//Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP−IJCNLP). Stroudsburg, PA, USA: ACL, 2019: 4216−4225. DOI: 10.18653/v1/d19−1431.

[10] Guo L, Sun Z, Hu W. Learning to Exploit Long-term Relational Dependencies in Knowledge Graphs[C]//International Conference on Machine Learning. Cambridge: PMLR, 2019: 2505−2514.

[11] Xiong W H, Yu M, Chang S Y, *et al*. One-shot Relational Learning for Knowledge Graphs[C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. Stroudsburg, PA, USA: ACL, 2018: 1980−1990. DOI: 10.18653/v1/d18−1223.

[12] Sheng J W, Guo S, Chen Z Y, *et al*. Adaptive Attentional Network for Few-shot Knowledge Graph Completion [C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). Stroudsburg, PA, USA: ACL, 2020: 1681−1691. DOI: 10.18653/v1/2020.emnlp−main.131.

[13] Wang Z, Zhang J W, Feng J L, *et al*. Knowledge Graph Embedding by Translating on Hyperplanes[J]. *Proc AAAI Conf Artif Intell*, 2014, **28**(1): 1112−1119. DOI: 10.1609/aaai.v28i1.8870.

[14] Lin Y K, Liu Z Y, Sun M S, *et al*. Learning Entity and Relation Embeddings for Knowledge Graph Completion [J]. *Proc AAAI Conf Artif Intell*, 2015, **29**(1): 2181−2187. DOI: 10.1609/aaai.v29i1.9491.

[15] Nickel M, Tresp V, Kriegel H P. A Three-way Model for Collective Learning on Multi-relational Data[C]// ICML. New York: ACM, 2011, **11**(10.5555): 3104482−3104584.

[16] 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). San Diego: ICLR, 2015.

[17] Dong X, Gabrilovich E, Heitz G, *et al*. Knowledge Vault: a Web-scale Approach to Probabilistic Knowledge Fusion [C]//Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2014: 601−610. DOI: 10.1145/2623330.2623623.

[18] Nguyen D Q, Nguyen T D, Nguyen D Q, *et al*. A Novel Embedding Model for Knowledge Base Completion Based onConvolutional Neural Network[C]//Proceedings of the 2018 Conference of the North American Chapter Ofthe Association for Computational Linguistics: Human LanguageTechnologies, Volume 2 (Short Papers). Stroudsburg, PA, USA: ACL, 2018: 327−333.. DOI: 10.18653/v1/n18−2053.

[19] Dettmers T, Minervini P, Stenetorp P, *et al*. Convolutional 2D Knowledge Graph Embeddings[J]. *Proc AAAI Conf Artif Intell*, 2018, **32**(1): 1811−1818. DOI: 10.1609/aaai.v32i1.11573.

[20] Schlichtkrull M, Kipf T N, Bloem P, *et al*. Modeling Relational Data with Graph Convolutional Networks[M]// The Semantic Web. Cham: Springer International Publishing, 2018: 593−607. DOI: 10.1007/978-3-319-93417-4_38.

[21] Luo P F, Zhu X, Xu T, *et al*. Semantic Interaction Matching Network for Few-shot Knowledge Graph Completion[J]. *ACM Trans Web*, 2024, **18**(2): 1−19. DOI: 10.1145/3589557.

[22] Mohamed S K, Nováček V, Nounu A. Discovering Pro-

tein Drug Targets Using Knowledge Graph Embeddings [J]. *Bioinformatics*, 2020, **36**(2): 603−610. DOI: 10.1093/bioinformatics/btz600.

[23] Ma R X, Yu M F, Gao B Y, *et al*. Enhancing Path Information with Reinforcement Learning for Few-shot Knowledge Graph Completion[C]//2023 IEEE 29th International Conference on Parallel and Distributed Systems (ICPADS). New York: IEEE, 2023: 1603−1611. DOI: 10.1109/ICPADS60453.2023.00225.

[24] Zhang C X, Yao H X, Huang C, *et al*. Few-shot Knowledge Graph Completion[J]. *Proc AAAI Conf Artif Intell*, 2020, **34**(3): 3041−3048. DOI: 10.1609/aaai. v34i0 3.5698.

[25] Liu J, Fan C F, Zhou F Y, *et al*. Complete Feature Learning and Consistent Relation Modeling for Few-shot Knowledge Graph Completion[J]. *Expert Syst Appl*, 2024, **238**: 121725. DOI: 10.1016/j.eswa.2023.121725.

[26] Niu G L, Li Y, Tang C G, *et al*. Relational Learning with Gated and Attentive Neighbor Aggregator for Few-shot Knowledge Graph Completion[C]//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2021: 213−222. DOI: 10.1145/3404835.3462925.

[27] Chen S J, Yang B, Zhao C X. Simple and Effective Meta Relational Learning for Few-shot Knowledge Graph Completion[J]. *Optim Eng*, 2025, **26**(2): 869−889. DOI: 10.1007/s11081-024-09880-w.

[28] Mitchell T, Cohen W, Hruschka E, *et al*. Never-ending Learning[J]. *Commun ACM*, 2018, **61**(5): 103−115. DOI: 10.1145/3191513.