

基于图注意力机制的有向知识图谱推理研究

刘子怡, 谭小波, 付俊超, 郑杰

(沈阳理工大学 信息科学与工程学院, 沈阳 110159)

摘要: 针对大规模知识图谱推理任务中传统图神经网络(GNN)全局关系捕捉能力不足、推理效率低下等问题,提出一种基于图注意力机制的有向知识图谱推理模型 RED-GATv2+。首先,在有向图神经网络 RED-GNN 基础上,结合图注意力网络 GATv2 在获取节点全局语义特征同时获取邻居节点的信息,提高图谱推理的准确率。其次,为提升效率,通过加入动态负采样生成更具对抗性的负样本,利用层次化 Top-k 聚合筛选关键邻居节点,从而显著减少不必要的邻居传递与计算量。RED-GATv2+ 在 WN18RR、FB15k-237、NELL-995 三个数据集上仿真验证的结果表明了 RED-GATv2+ 模型的有效性。

关键词: 图神经网络;知识图谱推理;动态负采样;Top-k 聚合

中图分类号: TP391 **文献标志码:** A **DOI:** 10.3969/j.issn.1003-1251.2025.06.007

Study on Directed Knowledge Graph Inference Based on Graph Attention Mechanism

LIU Ziyi, TAN Xiaobo, FU Junchao, ZHENG Jie

(Shenyang Ligong University, Shenyang 110159, China)

Abstract: To address the issues of insufficient global relationship capturing ability and low inference efficiency of traditional graph neural networks (GNN) in large-scale knowledge graph inference tasks, a directed knowledge graph inference model RED-GATv2+ based on graph attention mechanism is proposed. Firstly, on the basis of the directed graph neural network model RED-GNN, the graph attention network GATv2 is used to improve the accuracy of graph inference by acquiring the global semantic features of the nodes while acquiring the information of the neighboring nodes. Secondly, to improve the efficiency, more adversarial negative samples are generated by adding dynamic negative sampling, and key neighbor nodes are screened using hierarchical Top-k aggregation, thus significantly reducing unnecessary neighbor passing and computation. The results of RED-GATv2+ simulation validation on three datasets, WN18RR, FB15k-237, and NELL-995, indicate the validity of the RED-GATv2+ model.

Key words: graph neural networks; knowledge graph inference; dynamic negative sampling; Top-k aggregation

知识图谱^[1]是一种以图结构形式组织和表示知识的技术,其中节点代表实体,边代表实体之间

的关系。知识图谱最早应用于搜索引擎优化。由于其强大的语义表示和推理能力,知识图谱目前

已成为人工智能领域的重要基础设施,支撑着智能问答、语义搜索、推荐系统等众多应用场景^[2]。

然而,现实世界中的知识图谱往往是不完整的,存在大量缺失的实体或关系,限制了知识图谱在真实场景中的应用效果。例如,在医疗领域,一个不完整的药物-疾病关联图谱可能导致错误的治疗方案推荐;在金融风控领域,缺失的企业关联关系可能影响风险评估的准确性^[3]。因此,知识图谱补全^[4]成为提升知识图谱可用性的关键技术,其核心目标是通过推理方法预测缺失的实体或关系,从而增强知识图谱的完备性和实用性。

图神经网络(GNN)^[5]的出现,弥补了传统神经网络无法有效处理非欧式数据的空白,对于推动人工智能向前发展具有里程碑的意义。GNN现已成为处理大量应用领域任务最优秀的学习框架之一,并已渗透到推荐系统^[6]、自然语言处理^[7-8]、计算机视觉^[9]、药物发现^[10]和异常检测^[11]等多个领域。

文献[12]在2014年提出将回声状态网络的概念扩展到图数据上,设计了一种能够处理大规模图数据的神经网络模型,减少了训练复杂度。文献[13]在2019年提出将图卷积神经网络(GCN)与门控循环单元(GRU)相结合,通过使用卷积层在图结构数据上进行端到端学习,极大地推动了GNN的应用。文献[14]在2019年提出了利用GCN学习图结构信息,并结合分支定界方法实现精确求解,通过GCN学习节点的重要性,指导分支定界法进行更高效的搜索,从而加速优化过程。文献[15]提出了SACN,通过将结构性注意力机制引入到图神经网络中,动态调整邻居节点的影响权重,提升了模型对图中复杂结构的处理能力。文献[16]系统分析了基于嵌入的知识图谱补全方法,指出GNN与传统嵌入方法的结合是当前研究的热点。文献[17]提出的CompGCN框架通过组合关系运算显著提升了多关系图谱的表示能力。文献[18]提出了一种自动化知识图谱补全框架AutoKGC,利用神经架构搜索(NAS)优化嵌入模型,在多个基准数据集上性能超越手工设计的模型。文献[19]开发的KGTransformer将Transformer架构引入知识图谱推理,通过关系感知的自注意力机制捕捉长距离依赖关系,显著提升了推理能力。文献[20]提出了有向图神经网络RED-GNN,引入了一种新的关系结构—关系有向图,并采用与查询相关的注意力机制选择强相关的边,该结构由重叠的关系路径组成,能够更有效

地捕捉知识图谱中的局部信息。

尽管知识图谱推理研究已取得了显著的进步,但仍面临着大规模图谱处理困难、噪声信息的引入以及邻节点结构信息的丢失带来的特征聚合不平衡等问题。

针对上述问题,本文提出一种基于图注意力机制的有向知识图谱推理模型RED-GATv2+,该模型在RED-GNN的基础上结合GATv2^[21]模型,利用GATv2的动态注意力机制捕捉重要的邻居节点信息,从而增强特征聚合能力,使模型能够更高效地处理复杂图谱中的信息。在此基础上,加入动态负采样和稀疏邻居矩阵聚合策略优化其推理效率,以期该模型在复杂图谱的推理任务中能较好地平衡准确率和推理速度。

1 RED-GNN 模型

RED-GNN通过构建基于实体和句子的全局图,利用GNN学习文档内实体之间的关系。RED-GNN采用多层GNN传播信息,使模型能够从跨级别的信息中挖掘复杂关系,并且结合了注意力机制,能够动态地分配不同节点的权重,提高对长文本和间接关系的建模能力。相比传统的句级关系抽取方法,RED-GNN能够通过GNN捕捉文档级的实体交互,提升关系抽取能力。但是基础的RED-GNN在关系复杂的知识图谱进行推理时存在着效率低、推理准确率不高的问题。为此,本文以该模型为基础进行改进,以达到更好的推理效果。

2 结合动态负采样和稀疏邻居矩阵聚合策略的RED-GATv2+

2.1 RED-GATv2+

本文将RED-GNN与GATv2结合,利用GATv2的动态注意力机制捕捉重要的邻居节点信息,从而增强特征聚合能力。首先将递归模块中的图结构学习能力与GATv2的动态权重分配机制相结合,使模型能够更高效地处理复杂图谱中的信息。然后利用推理模块进行推理,生成新的节点和边,通过计算相应指标来预测推理出来的节点和边是否符合逻辑。最后通过计算相应的指标评估模块来决定是否输出到原图谱中。

然而RED-GATv2模型在提高推理准确率的同时仍面临计算效率问题。在RED-GATv2模型

的基础上,加入了负采样和稀疏邻居聚合策略,利用动态负采样生成更具代表性的负样本,提高模型对正负样本的区分能力,同时通过层次化选择和 Top-k 稀疏邻居聚合,有效筛选出重要的邻居节点信息,避免冗余特征干扰。动态负采样和稀疏邻居聚合策略的融合,使模型在推理效率和准确性方面取得平衡,相比于 RED-GATv2 模型具备更高的推理效率。

RED-GATv2 + 模型利用动态负采样通过对比学习优化表征,以区分正负样本。结合动态负采样和稀疏邻居矩阵聚合策略的 RED-GATv2 + 模型结构如图 1 所示。图 1 中,输入层 $V_1 \sim V_n$ 表示初始输入的 n 个节点特征向量,递归更新中 $h_i^{(t)}$ 表示第 i 个节点第 t 次递归迭代后的最终节点嵌入,GATv2 模块的 e_{ij} 是节点 i 与节点 j 之间用于动态聚合邻居信息的注意力权重,GNN 聚合层和再次递归层中的 $h_1 \sim h_n, h'_1 \sim h'_n$ 分别代表 GNN 中聚合和递归处理后的中间隐藏状态, $V'_1 \sim V'_n$ 表示经过初步推理后的节点表征,在线性层中得到不同维度的线性变换 $S_1 \sim S_n$,用于计算模型指标。

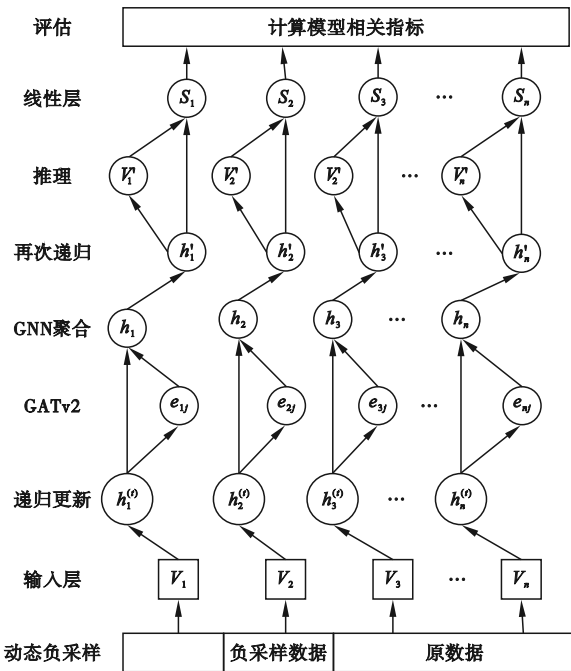


图 1 RED-GATv2 + 模型结构

Fig. 1 RED-GATv2 + model structure

2.2 RED-GATv2

RED-GNN 在很多公开数据集上与其他 GNN 方法相比表现优异,但是面对关系种类复杂且繁多的数据,其推理效果明显下降且推理速度较慢。一方面是数据过于复杂带来的准确率下降,另一方面是模型对于复杂关系数据的处理存在问题。

针对这一问题,本文选择在 RED-GNN 基础上加入图注意力模型 GATv2。该模型可以把输入的每个节点转化为特征矩阵,与其邻节点的特征矩阵进行线性变化,再配合图注意力机制对每个邻节点进行计算得到其权重,加权聚合邻节点的特征矩阵来更新自身特征矩阵表示,有利于提高图谱推理的准确率。模型整体结构如图 2 所示。

首先通过递归神经网络进行递归更新得到 $h_i^{(t)}$,捕捉节点在图中的全局依赖和时间序列特征,达到捕捉长程依赖和跨层次的信息交互。其次采用图注意力网络模型和 RED-GNN 模型对有向图谱的特征进行聚合更新得到 $h_1 \sim h_n, h'_1 \sim h'_n$,在推理模块中使用 RED-GNN 结合 GATv2 得到的特征 e_{ij} 对节点进行进一步的处理得到 $V'_1 \sim V'_n$,模型使用经过更新的节点特征来生成新的节点和边。将 RED-GNN 的递归特征与 GATv2 的注意力机制结合,形成 RED-GATv2 模型,通过动态调整邻居节点影响和多头注意力机制,捕捉全局依赖信息,提升复杂图谱推理表现,最后通过线性变换 $S_1 \sim S_n$ 计算模型性能指标并输出衡量模型推理结果的准确率和推理效果。

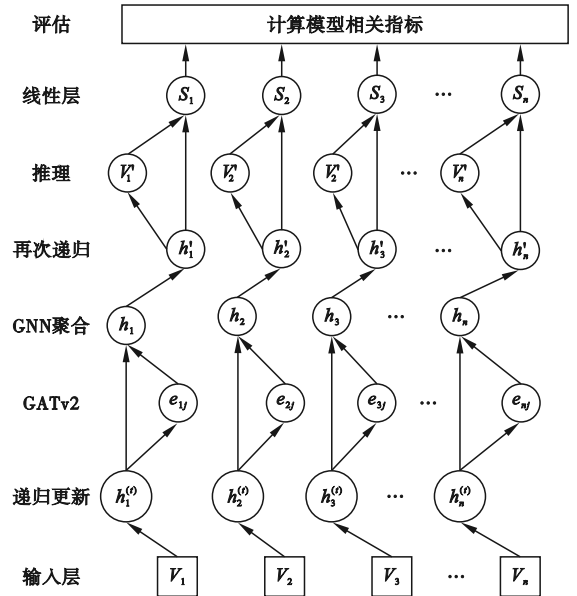


图 2 RED-GATv2 结构图

Fig. 2 RED-GATv2 structure diagram

2.3 动态负采样和稀疏邻居聚合策略

RED-GATv2 模型在提高推理准确率的同时面临计算效率的问题。尽管引入了递归编码和图注意力机制的组合,大幅提升了模型在复杂知识图谱推理任务中的准确率,但模型复杂度的增加导致了模型的运行时间显著增长。知识图谱推理往往需要处理完整的大规模图数据,节点及边的

数量达到数百万甚至更高,其中邻居节点信息聚合和图结构遍历操作使模型在训练和推理时面临巨大的计算开销。因此,在大规模图数据上,单纯追求准确率而不考虑效率的问题会导致模型在实际应用中无法有效部署。本文提出一种基于稀疏邻居聚合和动态负采样策略的优化方案,在略降低模型推理准确性的前提下,显著减少模型的运行时间,从而提升模型整体的计算效率。

在 GNN 中,节点的特征聚合和采样策略对模型的计算效率和表示能力有着至关重要的影响。负采样和稀疏邻居聚合结合策略能够在保持模型准确性的同时显著降低计算复杂度,并且有效提升模型在大规模知识图谱中的推理效率和训练性能。

首先,输入正样本三元组,并通过动态负采样生成对应的负样本。针对每个正负样本,通过层次化选择,将邻居节点按跳数分层,然后在每一层中应用 Top-k 策略筛选出最重要的邻居节点,从而构成稀疏邻居节点集合。接着,使用筛选后的邻居节点集合对正负样本进行特征聚合,生成嵌入表示,并对正负样本使用 GATv2 进行评分。最终通过损失函数优化,使模型能够区分正负样本,并逐步提升模型的准确性和泛化能力。上述流程结合了动态采样和稀疏聚合,有效提高了计算效率,同时提升了模型在图结构数据上的推理表现。

稀疏邻居聚合策略流程如图 3 所示。

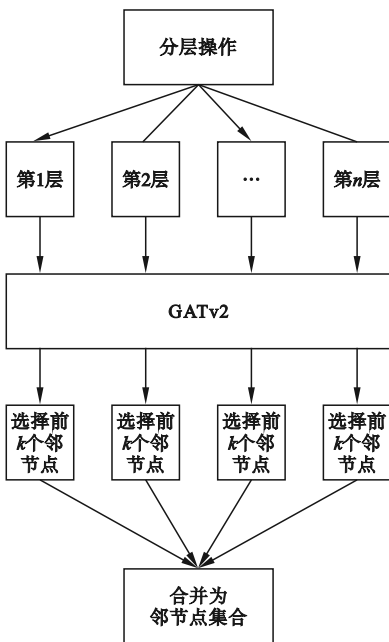


图 3 稀疏邻居聚合策略流程

Fig. 3 Sparse neighbors aggregation strategy workflows

3 实验与结果分析

3.1 训练环境

本文实验的软硬件环境配置如表 1 所示。

表 1 环境配置

Table 1 Environment configuration

软硬件名称	配置信息
CPU	Intel(R) Core(TM) i7 - 14700KF
GPU	RTX 4090 D 24 GB
内存	32 GB
操作系统	Windows11
开发语言	Python3. 12
开发框架	Pytorch1. 12. 5

3.2 数据集构建与评价指标

本文提出的 RED-GATv2 + 模型分别在 WN18RR^[22]、FB15k237^[22]、NELL-995^[22] 三个数据集上进行实验,数据集基础数据量如表 2 所示。

表 2 WN18RR、FB15k237、NELL-995 基础数据量

Table 2 WN18RR、FB15k237、NELL-995 of basic dataset size

数据集名	实体数量	关系类型数量	三元组数量
WN18RR	40 943	11	93 003
FB15k237	14 541	237	310 116
NELL-995	75 492	200	154 213

在推理任务中,常用的指标包括 MRR 和 Hits@k,评估模型在生成新节点和边时的推理效果。

MRR:表示所有正样本在预测列表中的平均倒数排名。

Hits@k:表示正样本在预测列表的前 k 名中是否出现。

本文将通过 MRR、Hits@1、Hits@10 等指标评估 RED-GATv2 + 模型的性能和推理结果。

3.3 参数设置

RED-GATv2 + 模型在训练的过程中对递归模块进行了微调,同时将其学习率与 GATv2 模块进行分离,得到更好的实验结果。为了避免训练中过拟合问题,采取加入 Dropout 的方法随机丢弃部分神经元。模型实验超参数设置如表 3 所示。

表3 实验超参数设置

Table 3 Experimental hyperparameters settings

参数名称	数值
学习率	0.001
正则化参数	0.000 946 5
注意力维度	32
Dropout	0.194 568
负斜率	0.09
优化器	AdamW
Top-k 初次筛选数量	10
GRU 层数	2
动态负采样比率	2
初始负采样数量	50
采样权重更新频率	10
学习率调度器	ExponentialLR
耐心数	10
正负样本比例	1:3

在加入超参数的基础上,加入以下策略进一步提高模型的训练效率。

1) 早停策略:监控验证集 MRR,连续数个训练轮次无提升则停止训练,防止过拟合并节省时间。

2) 显存优化:针对知识图谱节点邻域大的特点,限制邻居聚合参数和递归层数,减少 GPU 内存占用。

3) 样本比例:动态负采样时保持正负样本比例恒定,确保模型充分学习区分特征,提升训练效果。

3.4 实验结果对比

本文选取了 RNNLogic^[23]、CompGCN^[24]、RED-GNN 作为对比模型。在实验过程中,模型将从 MRR、Hits@1 和 Hits@10 三个方面进行评估,三个数据集的评价结果分别如表 4~6 所示。

表4 WN18RR 数据集下各个模型的评价结果

Table 4 Evaluation results for each model under the WN18RR dataset

模型	MRR	H@1/%	H@10/%
RNNLogic	0.483	44.6	55.8
CompGCN	0.479	44.3	54.6
RED-GNN	0.533	48.5	62.4
RED-GATv2	0.583	51.6	70.4
RED-GATv2 +	0.591	52.2	72.3

表5 FB15k237 数据集下各个模型的评价结果

Table 5 Evaluation results for each model under the FB15k237 dataset

模型	MRR	H@1/%	H@10/%
RNNLogic	0.344	25.2	53.0
CompGCN	0.355	26.4	53.5
RED-GNN	0.374	28.3	55.8
RED-GATv2	0.412	32.4	60.4
RED-GATv2 +	0.421	33.8	61.7

表6 NELL-995 数据集下各个模型的评价结果

Table 6 Evaluation results for each model under the NELL-995 dataset

模型	MRR	H@1/%	H@10/%
RNNLogic	0.416	36.3	47.8
CompGCN	0.463	38.3	59.6
RED-GNN	0.543	47.6	65.1
RED-GATv2	0.582	53.4	71.4
RED-GATv2 +	0.596	54.6	72.1

通过实验结果对比可以看出本文提出的 RED-GATv2 + 模型在三个数据集上的表现均优于其他模型。RNNLogic 是一种通过 RNN 模型捕捉图谱中逻辑关系的模型,但在三种数据集上性能均不及其他模型。CompGCN 是一种基于图卷积网络的模型,能够融合实体和关系特征,对于 FB15k237 数据集上稀疏数据带来的复杂关系捕捉能力明显不足。RED-GNN 的性能说明了动态递归编码的优越性,但缺乏灵活的注意力机制,使其表现稍逊。RED-GATv2 的性能明显优于以上三种模型,表明 GATv2 的动态多头注意力机制在捕捉节点重要性和建模复杂关系方面具有显著优势。RED-GATv2 + 在三个数据集上的性能均为最佳,负采样和稀疏邻居聚合结合策略有效提升了模型在大规模知识图谱中的性能。

为了验证加入稀疏邻居聚合和负采样策略的 RED-GATv2 + 模型在效率方面的提升,仍然在 WN18RR、FB15k237 和 NELL-995 三个数据集进行测试和训练。实验结果如图 4~6 所示。本次实验以在相同时间内达到的最高 MRR 值为标准进行评估,以此衡量模型在推理效率方面的优化效果。

由以上实验结果可以看出,CompGCN 在处理复杂的图数据时由于缺乏足够的特征聚合能力,MRR 增长幅度较小。RNNLogic 虽然结合了 RNN 模型的递归特性,但递归结构在复杂关系图




图 4 WN18RR 数据集下各模型运行速度

Fig. 4 Model running speed on WN18RR dataset




图 5 FB15k237 数据集下各模型运行速度

Fig. 5 Model running speed on FB15k237 dataset




图 6 NELL-995 数据集下各模型运行速度

Fig. 6 Model running speed on NELL-995 dataset

上较难有效提取高质量特征,因此在处理复杂的图结构时存在信息传递不足的问题。RED-GNN 使用了图神经网络框架,擅长在图结构中传播信息,因此在图谱推理中具有一定优势,但其特征聚合和信息传递能力相对不足,在较为复杂的数据集上稍显逊色。在 RED-GATv2 中,由于加入了 GATv2,模型的运行速度下降,在训练初始 1 h 左右的表现不如 RED-GNN,但整体准确率优于 RED-GNN 模型。RED-GATv2 + 加入了负采样和稀疏邻居聚合结合策略,能够在保持模型准确性

的同时显著降低计算复杂度,虽然 MRR 提升幅度减小,显著提升了模型的效率。

3.5 消融实验

为了进一步验证本文提出方法的有效性,分别在 WN18RR、FB15k237、NELL-995 三个数据集下设置了消融实验,结果如表 7~9 所示。

表 7 WN18RR 数据集下消融实验结果

Table 7 Results of ablation experiments under the WN18RR dataset

模型	MRR	H@ 1/%	H@ 10/%
RED	0.533	45.3	64.8
RED-GAT	0.562	48.9	65.5
RED-GATv2	0.583	51.6	70.4
RED-GATv2 +	0.591	52.2	72.3

表 8 FB15k237 数据集下消融实验结果

Table 8 Results of ablation experiments under the FB15k237 dataset

模型	MRR	H@ 1/%	H@ 10/%
RED	0.372	26.4	54.7
RED-GAT	0.394	29.1	57.9
RED-GATv2	0.412	32.4	60.4
RED-GATv2 +	0.421	33.8	61.7

表 9 NELL-995 数据集下消融实验结果

Table 9 Results of ablation experiments under the NELL-995 dataset

模型	MRR	H@ 1/%	H@ 10/%
RED	0.543	47.6	65.1
RED-GAT	0.572	50.3	66.8
RED-GATv2	0.582	53.4	71.4
RED-GATv2 +	0.596	54.6	72.1

表 7~9 中展示了不同模型在三种数据集上 MRR、H@ 1 和 H@ 10 指标的结果。三个数据集中四种模型的性能依次提升,表明 GAT 机制对模型性能的正向作用。其中,RED-GATv2 + 表现最佳,说明其预测准确率和召回率最高。实验验证了 GATv2 结构的有效性,并证明了 RED-GATv2 + 模型能够显著提升知识图谱任务的推理能力和效率。

4 结论

本文针对知识图谱推理任务中传统图神经网络全局关系捕捉能力不足、推理效率低下等问题,

提出一种基于图注意力机制的有向知识图谱推理模型 RED-GATv2+, 加入了动态负采样和稀疏邻居矩阵聚合两种策略, 并在三种数据集上完成训练和推理。实验结果表明该模型在减少计算开销的同时保持了高水平的准确性。

尽管本文提出的模型在准确性和效率方面相较于现有方法有所提升, 特别是在关系种类繁多的数据集上表现较好, 但仍存在一定的优化空间。未来的研究可以考虑进一步优化模型结构, 增加其对复杂关系的建模能力, 从而在更具挑战性的数据集上取得优异的性能。

参考文献 (References):

- [1] PENG C Y, XIA F, NASERIPARSA M, et al. Knowledge graphs: opportunities and challenges [J]. *Artificial Intelligence Review*, 2023, 56 (11) : 1 - 32.
- [2] ZENG Y, CHEN J T, XU J, et al. A tutorial on environment-aware communications via channel knowledge map for 6G [J]. *IEEE communications surveys & tutorials*, 2024, 26 (3) : 1478 - 1519.
- [3] JI S X, JIANG W Q, WALID A, et al. Dynamic sampling and selective masking for communication-efficient federated learning [J]. *IEEE Intelligent Systems*, 2021, 37 (2) : 27 - 34.
- [4] LIU X Y, WANG Z X, SUN Y, et al. ISA-KGC: integrated semantics-structure analysis in knowledge graph completion [J]. *IEEE Access*, 2024, 12 : 57250 - 57260.
- [5] LIU K, NIE G B, JIAO S B, et al. Research on fault diagnosis method of vehicle cable terminal based on time series segmentation for graph neural network model [J]. *Measurement*, 2024, 237 : 114999.
- [6] ZHANG M Q, WU S, YU X L, et al. Dynamic graph neural networks for sequential recommendation [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35 (5) : 4741 - 4753.
- [7] WU L F, CHEN Y, SHEN K, et al. Graph neural networks for natural language processing: a survey [J]. *Foundations and Trends in Machine Learning*, 2023, 16 (2) : 119 - 328.
- [8] 吕艳辉, 刘明鑫. 面向文本识别的 CRNN 模型的改进 [J]. *沈阳理工大学学报*, 2024, 43 (4) : 27 - 31.
LÜ Y H, LIU M X. Improvement of CRNN model for text recognition [J]. *Journal of Shenyang Ligong University*, 2024, 43 (4) : 27 - 31. (in Chinese)
- [9] QU H X, RAHMANI H, XU L, et al. Recent advances of continual learning in computer vision: an overview [J]. *IET Computer Vision*, 2025, 19 (1) : e70013.
- [10] ZHANG Z H, CHEN L F, ZHONG F S, et al. Graph neural network approaches for drug-target interactions [J]. *Current Opinion in Structural Biology*, 2022, 73 : 102327.
- [11] VEESAM S B, SATISH A R, TUPAKULA S, et al. Design of an integrated model with temporal graph attention and transformer-augmented RNNs for enhanced anomaly detection [J]. *Scientific Reports*, 2025, 15 : 2692.
- [12] 韩敏, 任伟杰, 许美玲. 一种基于 L1 范数正则化的回声状态网络 [J]. *自动化学报*, 2014, 40 (11) : 2428 - 2435.
HAN M, REN W J, XU M L. An improved echo state network via L1-norm regularization [J]. *Acta Automatica Sinica*, 2014, 40 (11) : 2428 - 2435. (in Chinese)
- [13] ZHAO L, SONG Y J, ZHANG C, et al. T-GCN: a temporal graph convolutional network for traffic prediction [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2020, 21 (9) : 3848 - 3858.
- [14] XU M J. Understanding graph embedding methods and their applications [J]. *SIAM Review*, 2021, 63 (4) : 825 - 853.
- [15] LI Z F, ZHAO Y, ZHANG Y, et al. Multi-relational graph attention networks for knowledge graph completion [J]. *Knowledge-Based Systems*, 2022, 251 : 109262.
- [16] ZHU Y Q, WANG X H, CHEN J, et al. Llms for knowledge graph construction and reasoning: recent capabilities and future opportunities [J]. *World Wide Web*, 2024, 27 (5) : 58.
- [17] CUI Y N, SUN Z Q, HU W. A prompt-based knowledge graph foundation model for universal in-context reasoning [J]. *Advances in Neural Information Processing Systems*, 2024, 37 : 7095 - 7124.
- [18] ZHANG Q, CHANG J L, MENG G F, et al. Learning graph structure via graph convolutional networks [J]. *Pattern Recognition*, 2019, 95 : 308 - 318.
- [19] SONG A P, XU X K, ZHAI X Y. SACN: a novel rotating face detector based on architecture search [J]. *Electronics*, 2021, 10 (5) : 558.
- [20] XIONG C R, XIAO J H, LI Z Y, et al. Knowledge graph network-driven process reasoning for laser metal additive manufacturing based on relation mining [J]. *Applied Intelligence*, 2024, 54 (22) : 11472 - 11483.
- [21] FU Y, LIU X D, YU B. PD-GATv2: positive difference second generation graph attention network based on multi-granularity in information systems to classification [J]. *Applied Intelligence*, 2024, 54 (6) : 5081 - 5096.
- [22] WANG Q, MAO Z D, WANG B, et al. Knowledge graph embedding: a survey of approaches and applications [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2017, 29 (12) : 2724 - 2743.
- [23] CHEN B F, HAO Z F, CAI X F, et al. Embedding logic rules into recurrent neural networks [J]. *IEEE Access*, 2019, 7 : 14938 - 14946.
- [24] LIU Y X, SANG G M, LIU Z, et al. MPTN: a message-passing transformer network for drug repurposing from knowledge graph [J]. *Computers in Biology and Medicine*, 2024, 168 : 107800.

(责任编辑: 和晓军)