

基于 LSTM 和卷积的时序知识图谱补全方法

许运生¹ 陈 美¹ 朱巧燕² 许 珂³
XU Yunsheng CHEN Mei ZHU Qiaoyan XU Ke

摘 要

时序知识图谱是一种表示实体及其语义关系随时间动态变化的结构化形式,用途广泛。然而,时序知识图谱通常存在不完整性,即部分实体和关系信息缺失。为了解决这一问题,时序知识图谱补全技术应运而生,其目标是通过已知信息来推断和补全缺失部分。然而,现有方法在实体、关系和时间信息的交互建模方面仍显不足,且时间信息的表示也有待进一步优化。为了解决上述挑战,文章提出了 LCCE (lstm-conv-conv embedding),该方法首先采用长短期记忆网络捕捉时间信息的层次性和依赖性,从而更有效地表示时间维度中的复杂动态变化。其次,通过卷积神经网络增强实体、关系和时间信息之间的深度交互,提高了知识表示的综合能力。在四个基准数据集上的实验结果表明,LCCE 的预测效果优于现有主流模型。

关键词

时序知识图谱补全; LSTM; 卷积神经网络; 特征交互; 循环卷积

doi: 10.3969/j.issn.1672-9528.2025.04.040

0 引言

知识图谱是一种以图结构形式表示知识的方法,在这一结构中,图的节点表示知识中的实体,而图的边则表示实体之间的关系^[1]。知识图谱广泛应用于问答系统^[2]、推荐系统^[3]、语义搜索^[4]等领域。时序知识图谱通过引入时间维度,具有动态表示实体及其关系随时间变化的特性,因而能够更全面地捕捉知识随时间演化的规律。然而,知识图谱普遍存在数据稀疏性问题,通常是不完整的,即部分实体和关系信息存在缺失。这种不完整性严重制约了其应用价值。为解决这一问题,研究者提出了知识图谱补全技术,通过已有知识来推断填补缺失部分,从而提升知识图谱的完整性。

静态知识图谱与时序知识图谱在结构上具有相似性,但在表示和处理上存在显著差异。静态知识图谱仅适用于描述静态关系,而时序知识图谱引入了时间信息来表示实体间关系的动态变化。近年来,许多方法在静态知识图谱补全任务上取得了良好性能,但这些方法无法有效利用时间信息,因此难以直接应用于时序知识图谱的补全任务。同时,现有时序知识图谱补全方法虽然能够在一定程度上利用时间信息来提高补全效果,但仍存在不足。例如,实体、关系和时间信息之间的交互建模不足,限制了模型性能;时间信息的处理

过于简单,无法挖掘更深层次的语义特征。

针对上述挑战,本文提出了一种结合长短期记忆网络(long short-term memory, LSTM)^[5]和卷积神经网络(convolutional neural network, CNN)的时序知识图谱补全方法 LCCE (lstm-conv-conv embedding)。本文主要贡献如下:

(1) 提出了时间信息提取模块。具体来说,将时间戳分解成年、月、日三个组件,并按顺序输入 LSTM,目的是捕捉时间信息的层次性与依赖性。随后将 LSTM 的输出输入卷积神经网络,从而获得更丰富的时间语义特征。

(2) 提出了混合特征交互模块。具体来说,将实体、关系和时间信息提取模块的输出进行堆叠重塑后输入卷积神经网络,目的是增强特征之间的交互能力,从而有效地实现头实体向尾实体的转换。

(3) 实验结果表明,LCCE 在四个基准数据集上的性能优于现有方法,验证了其在时序知识图谱补全任务中的有效性和实际应用潜力。

1 相关工作

1.1 静态知识图谱

知识图谱出现以来,研究者们已开发出多种有效的知识图谱补全方法,主要分为三类:平移型、张量分解型和神经网络型。

平移型以 TransE^[6]为代表,该方法将实体和关系嵌入到连续的向量空间,并通过将关系向量表示解释为头实体和尾实体向量之间的平移来实现推理。此类算法简单高效且低成

1. 南宁师范大学计算机与信息工程学院 广西南宁 530199
2. 惠州市第三人民医院 广东惠州 516001
3. 广东博罗农村商业银行股份有限公司 广东惠州 516001

本,但处理复杂关系(例如一对多、多对多关系)能力有限。

张量分解型模型则通过将知识图谱分解为低维空间中的多维张量。例如,DistMult^[7]是一种双线性模型,通过限制关系矩阵为对角矩阵,擅长捕捉关系的语义特征,但对非对称关系的处理能力有限。ComplEx^[8]进一步扩展了DistMult,通过将实体和关系嵌入到复数向量空间中,实现了对称和非对称关系的同时建模。GeomE^[9]在ComplEx的基础上引入多向量嵌入和几何乘积,对实体和关系进行更复杂的建模,从而显著增强了对关键关系模式的建模能力。

近年来,基于神经网络的方法在知识图谱补全任务中展现了显著的优势。例如,ConvE^[10]通过对实体和关系嵌入进行二维卷积,增强了特征交互能力,从而提高了模型的推理性能。然而,ConvE的固定结构限制了其对更复杂关系模式的表达能力。为此,InteractE^[11]在ConvE的基础上进行了改进,通过引入特征重排和特征重塑,进一步增强了嵌入特征的多样性和丰富度,有效提升了模型的预测性能。

上述模型在静态知识图谱补全任务中能够有效建模实体和关系之间的联系。然而,在实际应用中,实体间的关系会随着时间的推移发生变化,静态模型因缺乏对时间信息的利用,难以捕捉这种动态依赖性,从而导致知识表示不够完整或过时。为了解决这一问题,研究逐渐从静态模型扩展到时序知识图谱。

1.2 时序知识图谱

近年来,许多研究致力于扩展传统知识图谱补全模型,以捕捉时序知识图谱中的时间动态变化。其中,TTransE^[12]通过在TransE模型中引入时间信息,将时间视为嵌入表示中的一个额外维度。然而,TTransE简单地将时间信息建模为静态特征,忽略了时间信息的稀疏性和动态性,限制了其对时间演化规律的捕捉能力。

时间张量分解模型则通过在张量分解中引入时间信息来捕捉实体间复杂的时间变化关系。例如,TA-DistMult^[13]利用LSTM对时间戳进行序列建模,并将其与关系表示融合以增强时间感知能力。TComplEx和TNTComplEx^[14]通过在关系表示中融入时间信息,将四阶张量有效降低为三阶张量,从而改进了时间建模性能。TimePlex^[15]则进一步结合事件递归和时间交互,将实体、关系和时间嵌入到一个统一的空间中。TeLM^[16]对TComplEx进行了增强,分别通过复杂空间中的旋转和线性时间正则化器改进时间演化建模,从而捕捉时间依赖关系的动态特征。Joint-ComplEx^[17]借助静态模块辅助时间嵌入学习,通过共享静态信息和时间信息提升模型性能,而CEC-BD^[18]则引入基于块分解的时间位置学习方法,自然感知时间事实的顺序和距离。此外,TGeomE和TGeomE++^[19]将几何嵌入扩展到时序知识图谱,通过时间正

则化器赋予时间嵌入更强的几何意义。

综上所述,现有的静态和时序知识图谱补全方法在各自领域取得了显著进展,但在捕捉时间层次结构和周期性信息以及增强特征交互方面仍存在不足。未来的研究应致力于开发能够充分利用时间信息并增强特征交互的模型。

2 符号和定义

时序知识图谱(temporal knowledge graph, TKGs)是动态的知识的结构化表示,可以用一组四元组 $\mathcal{G}=\{(s, r, o, \tau) | s, o \in E, r \in R, \tau \in T\}$ 表示,其中 E 、 R 和 T 分别是实体、关系和时间戳的集合, s 、 r 、 o 、 τ 分别是头实体、关系、尾实体和时间戳。

时序知识图谱补全(temporal knowledge graph completion, TKGc)旨在根据现有知识预测时序知识图谱中缺失的信息,包括缺失的关系、实体或时间信息。本文任务为实体预测,即预测查询 $(s, r, ?, \tau)$ 中缺失的尾实体 o 或查询 $(?, r, o, \tau)$ 中缺失的头实体 s 。

3 基于LSTM和卷积网络的时序知识图谱补全

如图1所示,LCCE由两个关键模块组成:时间信息提取模块(temporal information extract module, TIE)和混合特征交互模块(mixed feature interaction module, MFI)。TIE负责从时间戳中提取出丰富可靠的时间特征。MFI则通过增强实体、关系和时间信息的特征交互,提取出目标实体的嵌入表示。

3.1 时间信息提取模块(TIE)

为有效地完成时序知识图谱的任务,通常需要将时间信息引入到模型中。然而,时间戳中的年、月、日之间具有明确的顺序和依赖关系,直接将时间嵌入集成到模型中无法精确捕捉实体和关系随时间变化的语义与周期性特征。因此本文提出了基于LSTM的时间信息提取模块(TIE)。

由于年、月、日之间存在明显的时间顺序和依赖性,以及为了减少时间信息的离散性,首先将时间戳分割,得到年、月、日三个组件后,将其按顺序输入LSTM,进而获得含有相互依赖关系和层次结构的时间特征,其公式为:

$$h_y, h_m, h_d = \text{LSTM}(e_y, e_m, e_d) \quad (1)$$

然后,将LSTM的输出输入到卷积神经网络进行局部信息交互,这将进一步将获得更丰富可靠的时间特征,其公式为:

$$\hat{e}_y, \hat{e}_m, \hat{e}_d = \text{Conv}(h_y, h_m, h) \quad (2)$$

式中: $e_y \in \mathbb{R}^d$ 、 $e_m \in \mathbb{R}^d$ 、 $e_d \in \mathbb{R}^d$ 分别为时间戳 τ 所分割的年、月、日的初始嵌入; $h_y \in \mathbb{R}^d$ 、 $h_m \in \mathbb{R}^d$ 、 $h_d \in \mathbb{R}^d$ 分别为年、月、日组件的LSTM输出的隐藏表示;Conv是一维卷积操作; $\hat{e}$

$y \in \mathbb{R}^d$ 、 $\hat{e}_m \in \mathbb{R}^d$ 、 $\hat{e}_d \in \mathbb{R}^d$ 分别是年、月、日组件的最终表示； d 是嵌入维度。




图 1 LCCE 示意图

3.2 混合特征交互模块 (MFI)

近年来的研究表明，通过增加嵌入之间的相互作用，可以增强模型的表现力。而增加嵌入之间的相互作用可通过卷积神经网络实现。对此，本文提出了基于卷积神经网络的混合特征交互模块 (MFI)。

首先，MFI 将实体、关系和 TIE 模块输出的时间特征作为通道信息进行堆叠。随后，将堆叠后的特征重塑为二维矩阵，最后，将重塑后的嵌入输入到卷积网络，并将输出展平连接成一个向量，使用线性层将其投影到实体的嵌入空间 ($\mathbb{R}^d$)，用公式分别表示为：

$$e_{\text{stack}} = \text{stack}(e_s, e_r, \hat{e}_y, \hat{e}_m, \hat{e}_d) \quad (3)$$

$$e_{\text{reshape}} = \text{reshape}(e_{\text{stack}}) \quad (4)$$


$$\hat{e}_o = \text{vec}(f(e_{\text{reshape}} \otimes \omega))W \quad (5)$$

式中： $e_s \in \mathbb{R}^d$ 、 $e_r \in \mathbb{R}^d$ 分别表示头实体、关系的嵌入； $\hat{e}_y \in \mathbb{R}^d$ 、 $\hat{e}_m \in \mathbb{R}^d$ 、 $\hat{e}_d \in \mathbb{R}^d$ 分别表示年、月、日组件的最终表示；stack 表示堆叠操作； $e_{\text{stack}} \in \mathbb{R}^{5 \times d}$ 表示堆叠后的嵌入；reshape 表示特征重塑操作； $e_{\text{reshape}} \in \mathbb{R}^{5 \times w \times h}$ 表示重塑后的嵌入； w 、 h 分别表示重塑后的宽和高 ($d=w \times h$)； $\otimes$ 表示卷积操作； ω 表示卷积核； $e_{\text{circular}} \in \mathbb{R}^{n \times w \times h}$ 表示经过卷积后的嵌入； n 表示卷积通道数； f 表示 ReLU 函数； $\text{vec}(\cdot)$ 表示展平操作； W 表示可学习权重。

通过图 2 可知，与零填充的标准卷积相比，循环卷积可以用于捕捉实体、关系和时间嵌入之间的更复杂的特征交互，因为其允许特征以循环的方式相互影响，从而增强了模型的表达能力。二维输入 $I \in \mathbb{R}^{m \times n}$ 与滤波器 $\omega \in \mathbb{R}^{k \times k}$ 上的循环卷积定义为：

$$[I \otimes \omega]_{p,q} = \sum_{i=-\lfloor k/2 \rfloor}^{\lfloor k/2 \rfloor} \sum_{j=-\lfloor k/2 \rfloor}^{\lfloor k/2 \rfloor} I_{[p-i]_m, [q-j]_n} \omega_{i,j} \quad (6)$$

式中： $[x]_n$ 表示 x 模 n ； $\lfloor \cdot \rfloor$ 表示底函数； $\otimes$ 表示循环卷积； ω 表示卷积核。



(a) 标准卷积 (b) 循环卷积

图 2 标准卷积和循环卷积示意图

3.3 评分函数

TKGC 可以被建模为一个排序问题，其目标是学习一个评分函数，为真实或可能的事实四元组分配更高的分数。从形式上讲，LCCE 的评分函数定义为：

$$\psi(s, r, o, \tau) = g(\hat{e}_o \circ e_o) \quad (7)$$

式中： $\hat{e}_o$ 和 e_o 表示预测的尾实体和目标尾实体； g 表示 sigmoid 函数。

3.4 损失函数

LCCE 的训练目标是最小化负对数似然损失，计算公式为：

$$\mathcal{L}(y, p) = -\frac{1}{N} \sum_i (y_i \log(p_i) + (1 - y_i) \log(1 - p_i)) \quad (8)$$

式中： $y=1$ 表示正样本，即 $(s, r, o, \tau) \in \mathcal{G}$ ，否则 $y=0$ ； N 表示训练样本的数量； p 表示候选实体 o 是查询 $(s, r, ?, \tau)$ 的答案或候选实体 s 是查询 $(?, r, o, \tau)$ 的答案的预测概率，通过评分函数计算得出。

4 实验结果及分析

4.1 数据集

本文在四个公共基准数据集上进行了评估：ICEWS14、ICEWS05-15、YAGO11k^[21] 和 Wikidata12k。所有数据集均已预先分割为训练集、验证集和测试集，详细统计信息如表 1 所示。

表 1 时序知识图谱数据集详情

数据集	实体	关系	训练集	验证集	测试集
ICEWS14	7 128	230	72 826	8 941	8 963
ICEWS05-15	10 094	251	368 962	46 275	46 092
YAGO11k	10 623	10	16 408	2 050	2 051
Wikidata12k	12 554	24	32 497	4 062	4 062

ICEWS^[22] 数据集是综合危机预警系统 (integrated crisis early warning system) 的一部分，用于记录社会政治事件。该数据集包含了具有离散时间标注的事件，时间间隔为 1 天，例如 (barack obama, make a visit, south korea, 2014-03-15)。其中，ICEWS14 包括 2014 年内发生的事件，而 ICEWS05-15

则涵盖了 2005 年至 2015 年期间的事件。

YAGO11k 数据集是基于开放知识图谱 YAGO3^[23] 的子集。YAGO11k 中的事实均带有时间注释，并以时间间隔的形式表示，例如 (#subjectID, #relationID, #objectID, 2001-##-##, 2014-##-##)。为了缓解时间稀疏性，按照 HyTE 的方法，将具有时间间隔的事实离散化为多个带有单一时间戳的四元组，时间粒度限定为年份级别，月和日用“00”表示，例如 2015-00-00。

Wikidata12k 数据集是开放知识图谱维基数据 Wikidata^[24] 的子集，其数据格式与 YAGO11k 类似。时间范围为 1981 年至 1988 年。该数据集在处理时与 YAGO11k 一致。

4.2 评价指标

本文采用命中率 (Hits@k) 和平均倒数排名 (MRR) 作为主要评价指标。Hits@k 的计算公式为：

$$\text{Hits@k} = \frac{1}{N} \sum_i^N f(\text{rank}_i \leq k) \quad (9)$$

式中：k 通常取值为 1、3 和 10，用于衡量不同条件下模型的预测能力；rank_{*i*} 是第 *i* 个样本正确实体在候选实体排名中的位置；*f*(·) 是指示函数，如果 rank_{*i*} ≤ *k*，则返回 1，否则返回 0。

MRR 是通过将所有测试样本中目标实体的排名倒数相加，并将结果除以测试样本总数得到的，用于综合考虑正确实体在候选实体排名中的位置，其计算公式为：

$$\text{MRR} = \frac{1}{N} \sum_i^N \frac{1}{\text{rank}_i} \quad (10)$$

式中：N 是样本总数。

与 Hits@k 一样，MRR 值越高，表明模型对测试事实的预测效果越好。此外，本文与基线方法一致，采用过滤设置

(Filtered Setting)^[25] 进行评估，即如果构造的负样本在时序知识图谱中已存在，则应在排序之前将该负样本过滤掉，以避免对评估结果产生干扰。

4.3 环境及参数设置

运行环境：Intel(R) Xeon(R) Gold 6133 CPU @ 2.5 GHz，NVIDIA GeForce RTX 3090，内存 24 GB，PyTorch 框架。

参数设置：最大训练轮次 epoch=200，批次大小 batch_size=1024，学习率 lr=0.001。负样本数量 neg_num=1000。特征维度 *d*=200，*w*=10，*h*=20。循环卷积核尺寸 ker_sz=9，卷积通道数 *n*=200，dropout=0.3。

4.4 对比模型

基线方法包括 SKGC 模型和 TKGC 模型。SKGC 模型包括 TransE、DistMult、ComplEx 和 InteractE。TKGC 模型包括 TA-DistMult、TComplEx(x10)、TimePlex、TNTComplEx(x10)、TeLM、TGoemE++、CEC-BD 和 Joint-ComplEx。选择这些基线方法的依据是它们在应对 TKGC 挑战方面的有效性，其中大多数方法都在四个以上的数据集上进行过测试。

4.5 实验设计与对比

4.5.1 实体预测

表 2 显示了 ICEWS14 和 ICEWS05-15 数据集上的实体预测结果。表 3 显示了 YAGO11k 和 Wikidata12k 数据集上的实体预测结果。最佳结果以粗体显示，次优结果用下划线显示，数值均为百分率。

由表 2 至表 3 可知，LCCE 在四个数据集上的大部分指标上取得了最优或次优的性能。具体而言，在 ICEWS14 数

表 2 ICEWS14 和 ICEWS05-15 上的实体预测结果比较

	ICEWS14				ICEWS05-15			
	Hit@1	Hit@3	Hit@10	MRR	Hit@1	Hit@3	Hit@10	MRR
TransE (2013)	9.4	—	63.7	28.0	9.0	—	66.3	29.4
DistMult (2014)	32.3	—	67.2	43.9	33.7	—	69.1	45.6
ComplEx (2016)	35.0	54.0	71.0	47.0	37.0	55.0	73.0	49.0
InteractE (2020)	36.4	54.6	71.3	48.2	36.8	54.9	71.9	48.7
TA-DistMult (2018)	36.3	—	68.6	47.7	34.6	—	72.8	47.4
TComplEx(x10) (2020)	53.0	66.0	77.0	61.0	59.0	71.0	80.0	66.0
TimePlex (2020)	51.5	—	77.1	60.4	54.5	—	81.8	64.0
TNTComplEx(x10) (2020)	52.0	66.0	76.0	62.0	59.0	71.0	81.0	67.0
TeLM (2021)	54.5	67.3	77.4	62.5	59.9	72.8	82.3	67.8
TGoemE++ (2023)	54.6	<u>68.0</u>	<u>78.0</u>	62.9	60.5	73.6	<u>83.3</u>	68.6
CEC-BD (2024)	<u>55.4</u>	<u>68.0</u>	77.7	<u>63.3</u>	60.2	73.0	82.5	68.1
Joint-ComplEx (2024)	54.7	67.7	78.3	62.9	59.8	73.5	83.1	68.1
LCCE (Ours)	55.8	68.1	77.4	63.4	60.7	73.8	82.6	<u>68.5</u>

表 3 YAGO11k 和 Wikidata12k 上的实体预测结果比较

	YAGO11k				Wikidata12k			
	Hit@1	Hit@3	Hit@10	MRR	Hit@1	Hit@3	Hit@10	MRR
TransE (2013)	1.5	13.8	24.4	10.0	10.0	19.2	33.9	17.8
DistMult (2014)	10.7	16.1	26.8	15.8	11.9	23.8	46.0	22.2
ComplEx (2016)	—	—	—	—	12.3	25.3	43.6	23.3
InteractE (2020)	9.4	14.9	26.1	14.7	14.4	25.5	43.2	23.7
TA-DistMult (2018)	10.3	17.1	29.2	16.1	12.2	23.2	44.7	21.8
TComplEx(x10) (2020)	12.7	18.3	30.7	18.5	23.3	35.7	53.9	33.1
TimePlex (2020)	<u>16.9</u>	-	<u>36.7</u>	<u>23.6</u>	22.8	-	53.2	33.4
TNTComplEx(x10) (2020)	12.7	18.3	30.7	18.5	23.3	35.7	53.9	33.1
TeLM (2021)	12.9	19.4	32.1	19.1	23.1	36.0	54.2	33.2
TGoemE++ (2023)	13.0	19.6	32.6	19.5	—	—	—	—
CEC-BD (2024)	15.4	<u>21.5</u>	33.9	21.2	24.1	36.9	54.3	33.9
Joint-ComplEx (2024)	12.7	20.4	33.9	19.6	<u>25.6</u>	<u>38.0</u>	<u>55.0</u>	<u>34.9</u>
LCCE (Ours)	18.7	26.7	39.2	25.2	30.5	47.4	62.5	41.4

数据集上的 Hit@1、Hit@3 和 MRR 达到最优；在 ICEWS05-15 数据集上的 Hits@1 和 Hit@3 达到最优，MRR 达到了次优；在 YAGO11k 和 Wikidata12k 数据集上的四个指标均达到最优。总体来说，LCCE 可以有效地提升实体预测的性能。

实验结果分析如下：

(1) 大多数 TKGC 模型的结果显著优于 SKGC 模型，例如，LCCE 在四个数据集 ICEWS14、ICEWS05-15、YAGO1k 和 Wikidata12k 上的 MRR 值，相比于 SKGC 模型的 InteractE 分别提升了 31.3%、40.7%、71.4% 和 74.7%。主要原因是 TKGC 模型利用时间信息来约束事实的相似性，从而有效地分离具有不同时间戳的相似事实。

(2) LCCE 模型的结果普遍优于将时间视为独立的实体的模型，主要原因是 LCCE 将时间戳分割为多个组件，利用时序模型（如 LSTM）学习时间的层次结构和依赖关系，具有更强的动态捕捉能力。

(3) LCCE 模型的结果普遍优于平移模型和张量分解模型，主要原因是 LCCE 不仅捕捉了时间信息的层次依赖，还增强了嵌入特征间的交互能力。这两者的结合使得模型可以更充分的利用时间信息，增强模型的表现力。

综上所述，LCCE 能够更准确地更好地捕捉时序知识图谱中正确的复杂的时间依赖关系，从而在各项评估指标上达到最先进水平。

4.5.2 消融实验

LCCE 引入了时间信息（Time）、LSTM 和卷积神经网络（Conv），为了验证这些组件的有效性，在 ICEWS14 数据集上进行了消融实验，实验结果如表 4 所示。用“√”表示实验中使用的组件，用“×”表示不存在相应的组件。

表 4 ICEWS14 和 ICEWS05-15 上的实体预测结果比较

Time	LSTM	Conv	Hit@1	Hit@3	Hit@10	MRR
×	×	×	36.1	54.1	71.1	47.9
√	×	×	54.5	67.3	<u>76.9</u>	62.4
√	√	×	54.6	67.9	77.4	62.8
√	√	√	55.8	68.1	77.4	63.4

从表 4 的结果发现：

(1) 不使用时间信息的模型表现最差，这表明时间信息在 TKGC 中的重要性。时序知识图谱中的实体关系随时间变化，时间信息能够帮助模型捕捉这些动态变化，因此忽略时间信息会显著降低模型的预测能力。

(2) 结合时间信息和 LSTM 的模型效果明显优于仅使用时间信息的模型。这表明 LSTM 在捕捉时间信息的依赖关系和层次结构方面具有重要作用。LSTM 能够处理序列数据，捕捉时间序列中不同时间点之间的依赖关系，从而更好地提取时间特征。

(3) 使用卷积神经网络对时间信息进一步提取时，模型达到了最佳效果。这是因为卷积神经网络可以对时间信息进行局部特征的细粒度提取，从而进一步提升了模型的表现。

综上所述，消融实验验证了时间信息、LSTM 的层次依赖捕捉以及卷积神经网络的局部信息提取在提升时序知识图谱补全任务中的效果。

5 结语

为解决 TKGC 中时间信息提取不足以及实体、关系和时间之间交互不足的问题，本文提出了 LCCE 模型。具体来说，

LCCE 首先将时间戳分割为年、月、日, 将其输入到 LSTM 和卷积神经网络, 获得具有层次性和依赖性的丰富可靠的时间特征。然后将实体、关系和年、月、日三个时间特征进行堆叠和重塑, 并将其输入到循环卷积网络, 以此增强实体、关系和时间信息的特征交互。实验结果表明, LCCE 在多个基准数据集上的多项评估指标上均优于现有方法。

参考文献:

- [1] LI J H, WANG Z Q, WANG Y, et al. Research on distributed search technology of multiple data sources intelligent information based on knowledge graph[J]. Journal of signal processing systems, 2020, 93: 239-248.
- [2] CHEN Z Y, LIAO J Z, ZHAO X. Multi-granularity temporal question answering over knowledge graphs[C]//Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics. Brussels: ACL, 2023: 11378-11392.
- [3] QIN Y R, GAO C, WEI S Q, et al. Learning from hierarchical structure of knowledge graph for recommendation[J]. ACM transactions on information systems, 2023, 42(1): 1-24.
- [4] PENG C Y, XIA F, NASERIPARSA M, et al. Knowledge graphs: opportunities and challenges[J]. Artificial intelligence review, 2023, 56(11): 13071-13102.
- [5] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural computation, 1997, 9(8): 1735-1780.
- [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. New York: ACM, 2013: 2787-2795.
- [7] PAN S R, LUO L H, WANG Y F, et al. Unifying large language models and knowledge graphs: a roadmap[J]. IEEE transactions on knowledge and data engineering, 2024, 36(7): 3580-3599.
- [8] TROUILLON T, WELBL J, RIEDEL S, et al. Complex embeddings for simple link prediction[C]//Proceedings of the 33rd International Conference on International Conference on Machine Learning. New York: JMLR.org, 2016: 2071-2080.
- [9] XU C J, NAYYERI M, CHEN Y Y, et al. Knowledge graph embeddings in geometric algebras[C]//Proceedings of the 28th International Conference on Computational Linguistics. Brussels: ACL, 2020: 530-544.
- [10] 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 AAAI Symposium on Educational Advances in Artificial Intelligence. New York: ACM, 2018: 1811-1818.
- [11] VASHISHTH S, SANYAL S, NITIN V, et al. Interact: improving convolution-based knowledge graph embeddings by increasing feature interactions[DB/OL]. (2020-09-24) [2024-09-15]. <https://doi.org/10.48550/arXiv.1911.00219>.
- [12] JIANG T S, LIU T Y, GE T, et al. Towards time-aware knowledge graph completion[C]//Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics: Technical Papers. Brussels: ACL, 2016: 1715-1724.
- [13] LIANG K, MENG L Y, LIU M, et al. Learn from relational correlations and periodic events for temporal knowledge graph reasoning[C]//SIGIR'23: Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2023: 1559-1568.
- [14] LIU Y S, MA Y P, HILDEBRANDT M, et al. Tlogic: temporal logical rules for explainable link forecasting on temporal knowledge graphs[J]. AAAI conference on artificial intelligence, 2022, 36(4): 4120-4127.
- [15] JAIN P, RATHI S, CHAKRABARTI S. Temporal knowledge base completion: New algorithms and evaluation protocols[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). Brussels: ACL, 2020: 3733-3747.
- [16] XU C J, CHEN Y Y, NAYYERI M, et al. Temporal knowledge graph completion using a linear temporal regularizer and multivector embeddings[C]//Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Brussels: ACL, 2021: 2569-2578.
- [17] ZHANG F, CHEN H Z, SHI Y Z, et al. Joint framework for tensor decomposition-based temporal knowledge graph completion[J]. Information sciences, 2024, 654: 119853.
- [18] YUE L P, REN Y J, ZENG Y, et al. Complex expressional characterizations learning based on block decomposition for temporal knowledge graph completion[J]. Knowledge-based systems, 2024, 290: 111591.
- [19] XU C J, NAYYERI M, CHEN Y Y, et al. Geometric algebra based embeddings for static and temporal knowledge graph completion[J]. IEEE transactions on knowledge and data engineering, 2022, 35(5): 4838-4851.

(下转第 179 页)

参考文献:

- [1] HECHT J. Lidar for self-driving cars[J]. Optics and photonics news,2018,29(1):26-33.
- [2] WOOPEN T, LAMPE B, BODDEKER T,et al.UNICARagil - disruptive modular architectures for agile, automated vehicle concepts[C]//Aachen Colloquium Automobile and Engine Technology 2018. Berlin:Springer,2018:663-694.
- [3] Point cloud compression category 13 reference software, TMC13-v14.0[EB/OL]. (2021-10-22)[2024-08-06].htx.int-evry.fr/software/MPEG/PCC/TM/mpeg-pcc-tmc13/tree/release-v14.0.
- [4] SRIDHARA S N, PAVEZ E, ORTEGA A. Cylindrical coordinates for lidar point cloud compression[C]//2021 IEEE International Conference on Image Processing (ICIP). Piscataway: IEEE, 2021: 3083-3087.
- [5] SCHNABEL R, KLEIN R. Octree-based point-cloud compression[C]//Proceedings of the 3rd Eurographics/IEEE VGTC conference on Point-Based Graphics. NewYork:ACM,2006:111-121.
- [6] HOUSHIAR H, NÜCHTER A. 3D point cloud compression using conventional image compression for efficient data transmission[C]// 2015 XXV International Conference on Information, Communication andAutomation Technologies (ICAT).

Piscataway:IEEE,2015: 1-8.

- [7] SUN X B, MA H, SUN Y X, et al.A novel point cloud compression algorithm based on clustering[J].IEEE robotics and automation letters, 2019, 4(2): 2132-2139.
- [8] SANG L. Wavelet transform based video compression algorithm and its application in video transmission[J]. Computer modeling & new technologies, 2013, 17(5B): 60-63.
- [9] OORD A V D, KALCHBRENNER N, KAVUKCUOGLU K. Pixel recurrent neural networks[C]// Proceedings of the 33rd International Conference on International Conference on Machine Learning. NewYork: ACM, 2016:1747-1756.
- [10] GEIGER A, LENZ P, STILLER C, et al. Vision meets robotics: the KITTI dataset[J]. International journal of robotics research, 2013, 32(11):1231-1237.

【作者简介】

石元龙（2000—），男，安徽芜湖人，硕士研究生，研究方向：点云编码。

郑明魁（1976—），男，福建福州人，博士，副教授，研究方向：点云编码与视频编码。

（收稿日期：2024-12-06）

（上接第 175 页）

- [20] GUAN Y N, LIAO S J, WAGG W Y. AParC-DETR: accelerate DETR training by introducing Adaptive position-aware circular convolution[J]. The visual computer, 2024, 41: 1319-1333.
- [21] DASGUPTA S S, RAY S N, TALUKDAR P. HYTE: hyperplane-based temporally aware knowledge graph embedding[C]//Proceedings of the 2018 conference on empirical methods in natural language processing. Brussels: ACL, 2018: 2001-2011.
- [22] JIA N N, YAO C Y. A brief survey on deep learning-based temporal knowledge graph completion[J]. Applied sciences, 2024, 14(19): 8871.
- [23] SUCHANEK F M, ALA, M, BONALD T, et al. Yago 4.5: a large and clean knowledge base with a rich taxonomy[C]// Proceedings of the 47th International ACM SIGIR Conference on Research and Development in Information Retrieval. NewYork:ACM, 2024: 131-140.

- [24] NIAZMAND E, VIDAL M E. Discovering relationships among properties in wikidata knowledge graph[J]. Big data analytics and knowledge discovery, 2024(18): 388-394.
- [25] XU C J, NAYYERI M, ALKHOURY F, et al. Tero: a time-aware knowledge graph embedding via temporal rotation[C]// Proceedings of the 28th International Conference on Computational Linguistics.Brussels: ACL, 2020: 1583-1593.

【作者简介】

许运生（1992—），男，广东惠州人，硕士研究生，研究方向：语义 Web、深度学习。

陈美（2000—），女，广西陆川人，硕士研究生，研究方向：语义 Web、机器学习。

朱巧燕（1994—），女，广东惠州人，硕士研究生，研究方向：系统可靠性。

许珂（1994—），男，广东惠州人，硕士研究生，研究方向：系统可靠性。

（收稿日期：2024-12-07）