

基于自适应上下文匹配网络的小样本知识图谱补全

杨旭华, 张炼, 叶蕾

引用本文

杨旭华, 张炼, 叶蕾. [基于自适应上下文匹配网络的小样本知识图谱补全](#)[J]. 计算机科学, 2024, 51(5): 223-231.

YANG Xuhua, ZHANG Lian, YE Lei. [Adaptive Context Matching Network for Few-shot Knowledge Graph Completion](#) [J]. Computer Science, 2024, 51(5): 223-231.

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)

[基于多视图自编码器的多被试者脑影像功能校准](#)

Multi-view Autoencoder-based Functional Alignment of Multi-subject fMRI
计算机科学, 2024, 51(3): 141-146. <https://doi.org/10.11896/jsjcx.230600166>

[基于对比学习的时间序列聚类方法](#)

Time Series Clustering Method Based on Contrastive Learning
计算机科学, 2024, 51(2): 63-72. <https://doi.org/10.11896/jsjcx.221200038>

[基于生成式对抗网络和正类无标签学习的知识图谱补全算法](#)

Knowledge Graph Completion Algorithm Based on Generative Adversarial Network and Positive and Unlabeled Learning
计算机科学, 2024, 51(1): 310-315. <https://doi.org/10.11896/jsjcx.230300006>

[基于深度学习的羽毛球知识图谱补全模型构建](#)

Construction of Badminton Knowledge Graph Completion Model Based on Deep Learning
计算机科学, 2023, 50(11A): 220900205-6. <https://doi.org/10.11896/jsjcx.220900205>

[基于贝叶斯规则的具有层次注意力的知识补全](#)

Bayesian Rule-based Knowledge Completion with Hierarchical Attention
计算机科学, 2023, 50(11): 234-240. <https://doi.org/10.11896/jsjcx.221000056>

基于自适应上下文匹配网络的小样本知识图谱补全

杨旭华 张炼 叶蕾

浙江工业大学计算机科学与技术学院 杭州 310023

(xhyang@zjut.edu.cn)

摘要 知识图谱在构建过程中需要面对繁杂的现实世界信息,无法建模所有知识,因此需要补全。真实的知识图谱中很多类型的关系通常只有少量的训练实体样本对。因此,如何进行小样本知识图谱补全是一个十分有价值的问题。目前基于嵌入的方法一般通过注意力机制等方法聚合实体上下文信息,通过学习关系嵌入的方式来补全知识图谱,仅考虑关系层面的匹配程度,虽然能够预测未知关系,但往往准确度不高。针对小样本知识图谱补全问题,提出了一个自适应上下文匹配网络(Adaptive Context Matching Network, ACMN)。首先提出一个共性邻居感知编码器,聚合参考集实体上下文,即一跳邻居实体,获得共性邻居感知编码;接着提出一个任务相关实体编码器,挖掘任务实体上下文与共性上下文的相似度信息,区分一跳邻居对当前任务的贡献,增强实体表征;然后提出一个上下文关系编码器获得动态关系表征;最后通过加权求和综合考虑实体上下文和关系的匹配程度,完成补全。ACMN从实体上下文相似度和关系匹配程度两个方面综合评价查询三元组是否成立,能够在小样本的背景下有效提高预测准确性。在两个公共数据集上和其他8个广泛使用的算法进行比较,ACMN在不同规模的小样本情况下,取得了目前最好的补全结果。

关键词: 知识图谱补全;小样本学习;实体上下文;关系预测;表示学习

中图分类号 TP181

Adaptive Context Matching Network for Few-shot Knowledge Graph Completion

YANG Xuhua, ZHANG Lian and YE Lei

College of Computer Science and Technology, Zhejiang University of Technology, Hangzhou 310023, China

Abstract The knowledge graph needs to face complicated real world information in construction process, and cannot model all knowledge, so it needs to be completed. Many relations in real knowledge graph often have only few entity pairs for training. Therefore, few-shot knowledge graph completion is a very significant problem. At present, embedding-based methods generally aggregate entity context information through attention mechanism or other methods, and complete knowledge graph by learning relation embeddings. These methods only consider the matching degree at relation level. Although they can predict unknown relations, the result is often not accurate. Therefore, an adaptive context matching network (ACMN) is proposed for few-shot knowledge graph completion. Firstly, a common-neighbor awareness-encoder is proposed to aggregate the references context, that is, one-hop neighbor entities, and obtain common-neighbor awareness embeddings. Secondly, a task-related entity encoder is proposed to mine the similarity information between task entity context and common context, distinguish the contribution of one-hop neighbors to the current task, and enhance task entity representation. Then a context-relation encoder is proposed to obtain dynamic relation representations. Finally, the matching degree of entity context and relations is comprehensively considered through weighted summation to complete the completion. ACMN comprehensively evaluates whether the query triples are tenable from two aspects of entity context similarity and relations matching, which can effectively improve the prediction accuracy in few-shot scenarios. Compared with other eight widely used algorithms on the two public data sets, ACMN achieves the best completion results in the case of different few-shot sizes.

Keywords Graph completion, Few-shot learning, Entity context, Relation prediction, Representation learning

到稿日期:2023-02-02 返修日期:2023-05-18

基金项目:国家自然科学基金(62176236)

This work was supported by the National Natural Science Foundation of China(62176236).

通信作者:叶蕾(yelei@zjut.edu.cn)

1 引言

知识图谱是当前赋予机器知识的一种重要载体^[1],在推荐系统^[2-4]、问答系统^[5-6]以及语义搜索^[7-8]等领域具有广泛的应用。知识图谱是一个异构有向图,由许多包含头实体、关系和尾实体的三元组构成。知识图谱一般由人工或者通过 AI 的方法构建,在构建过程中需要面对繁杂的现实世界信息,无法做到建模所有的知识,因此具有不完整性,表现为关系稀疏或者未充分挖掘隐含关系。目前已经有知识图谱补全的研究^[9-12]。例如,Trans 系列模型^[13-15]将实体间的关系表示为从头实体向量向尾实体向量的一种平移操作;GRL^[9]基于强化学习和生成对抗网络来进行补全;TransEdge^[16]以边为中心完成嵌入,用特定的头尾实体对来获得包含上下文信息的关系表征。一般的知识图谱补全方法要求每种关系拥有大量的头尾实体对,才能通过训练拟合补全模型。但在现实的知识图谱中,很多关系涉及的三元组数量非常少,传统方法难以获得很好的补全效果。

目前很多学者已经对知识图谱的小样本补全问题进行了深入的研究。Xiong 等提出的单样本关系学习模型 GMatching^[17]利用实体所在背景图中的一跳邻居,来学习参考集实体的静态表征,丰富了实体对的语义信息。但是, GMatching 以取均值的方式聚合一跳邻居的结构信息,无法区分不同邻居对实体嵌入的贡献,同时,其设定在单样本的问题下,模型无法学习到多个训练实体对之间的关联信息。因此 Zhang 等提出了一种小样本关系学习模型 FSRL^[18],通过注意力机制,给不同的一跳邻居赋予了不同的权重,使得模型能够区分不同邻居对实体嵌入的贡献,获取更细粒度的图结构信息。同时用一种基于 LSTM 的聚合网络聚合参考集实体对的表示信息,来产生关系表征,考虑到了参考集中多个样本间的交互作用。以上方法通过取均值或利用注意力机制聚合实体上下文信息,学习关系嵌入的方式来补全,仅考虑了关系层面的匹配程度,虽然能够实现未知关系的补全,但往往准确度不高。

为了解决上述问题,本文提出了一个自适应网络 ACMN。对于不同的下游任务,ACMN 可以根据上下文自适应地获取任务相关实体和关系嵌入,从实体上下文相似度和关系匹配程度两个方面来综合考量查询三元组是否成立,从而进一步提升模型的性能,是解决小样本知识图谱补全问题的新范式。

本文的主要贡献如下:

1) ACMN 从实体上下文相似度和关系匹配程度两个方面考虑查询实体对与参考集实体对的匹配程度,综合评价查询三元组成立的程度,能在小样本的背景下提高补全准确性,是一个新的小样本知识图谱补全训练范式。

2) 提出了一个共性邻居感知编码器,能够通过注意力机制挖掘参考集不同实体的上下文具有的共性信息,对参考集实体上下文进行聚合来获取共性邻居感知编码,用于增强任务相关实体表征。

3) 提出了一个上下文关系编码器,将同一任务关系的

不同头尾实体对视作该关系的上下文,用增强的头尾实体表征来获得包含上下文信息的动态关系表征。

本文第 2 章介绍相关工作;第 3 章描述本文提出的自适应上下文匹配网络;第 4 章进行数值仿真和结果分析;最后总结全文并展望未来。

2 相关工作

2.1 基于表示学习的知识图谱补全

知识图谱补全的目的是预测知识图谱所缺失的部分,使其变得更加完备。按照补全方法的不同,目前知识图谱补全主要可以划分为 3 种类型,即平移距离模型、语义匹配模型和神经网络模型。在平移距离模型方面,Mikolov 等首次提出 Word2vec 词向量模型^[19]并发现在词向量空间中存在着平移不变现象,即两个语义相似的词在向量空间上也存在着一定相似性。同时发现平移不变的现象普遍存在于词汇的结构、语义之间的关系中。TransE^[13]将这种空间中平移不变的现象成功应用到了知识表示学习中。相比以往基于符号推理的模型,TransE 参数更少,计算复杂度更低,在大规模知识图谱上有明显的优势。在语义匹配模型方面,RESCAL^[20]首次进行语义匹配建模,它仍用向量 \mathbf{h}, \mathbf{t} 表示头尾实体,但关系 r 用矩阵 \mathbf{M}_r 进行表示,能够实现对潜在因子之间的成对相互作用进行建模。ComplEx^[21]在复数空间中学习实体和关系的向量表示,从而可以有效处理对称与反对称的关系。在神经网络模型方面,NTN^[22]中的关系被表示成一个三阶的张量,使得每个切片对应的语义类型各不相同,有利于描述和同一关系有关联的不同实体之间存在的各种语义联系。多层卷积神经网络模型 ConvE^[23]对实体和关系进行一个 2D 卷积操作,通过全连接网络输出三元组的得分,将向量空间中的计算问题转化为图像上的特征提取问题。G-GCN^[24]基于图神经网络对关系结构进行建模。

2.2 小样本学习

小样本学习旨在从有限的监督样本中学习^[25-26],目前常应用于机器视觉^[27]、商品推荐^[28]、文本分类^[29]和视觉问答^[30]等领域。近期研究中根据实现思路的不同,通常将小样本学习分为两类:1) 基于度量的方法^[31-33];2) 基于元优化的方法^[34-37]。基于度量的方法学习数据点之间的“距离度量”,然后通过将测试样本与 K 个带标签的样本进行比较来对其进行分类。这个“距离度量”由两部分构成:一个是嵌入函数,它将所有实例编码到一个表示空间中;另一个是相似度度量,如余弦相似度或欧几里得距离,以计算两个实例在空间中的接近程度。如果“距离度量”在训练任务中学习得很好,那么它无须微调就可以很好地用于目标任务。其中,Matching Network^[32]通过将输入样本与支持集中少量带标签的样本进行比较来预测,可以认为是一个嵌入空间内的权重近邻分类器。Prototypical Network^[33]在支持集中使用类表示,而不是样本表示,并且相似度度量的选择是至关重要的(欧几里得距离优于余弦相似度)。基于元优化的方法旨在通过少量的梯度下降优化步骤就学习到接近最优点的神经网络模型参数。MAML^[34]模型中提出了一种模型无关元学习方法,通过训练

集对模型进行微调,使得模型在验证集上有良好的表现。ATAML^[37]提出将参数分为任务无关部分和任务相关部分,设置有两个级别的优化,在任务级别,只针对任务相关部分的参数计算梯度;在元级别,任务无关部分和任务相关部分参数都将在训练中被更新。

3 自适应上下文匹配网络

针对小样本知识图谱补全问题,本文提出了自适应上下文匹配网络 ACMN。ACMN 从实体上下文相似度和关系匹配程度两个方面评价查询三元组是否成立,能够在小样本的背景下有效提高预测准确性。

3.1 问题描述

一个知识图谱 G 由一个三元组集合 $T = \{(h, r, t) \in \mathcal{E} \times \mathbf{R} \times \mathcal{E}\}$ 组成,其中 \mathcal{E} 和 \mathbf{R} 分别代表实体集和关系集,本文的目标是完成在小样本场景下的知识图谱链路预测任务。

一般情况下,一个知识图谱补全模型以三元组为单位进行训练,而在元学习的定义下,模型以元学习任务为单位进行训练。每一种关系 $r \in \mathbf{R}$ 会有一个参考集 $S_r = \{(h_k, t_k) | (h_k, r, t_k) \in T\}$,一个元学习任务是通过学习参考集中所蕴含的任务知识,从一个候选实体集 C 中预测出查询三元组 $(h, r, ?)$ 中缺失的尾实体。其中 $|S_r| = K, K$ 是一个小的正整数,比如 3 或 5。

为了和链路预测任务保持一致,每一个训练任务都对应一条任务关系 $r \in \mathbf{R}$,其包含的参考集和查询集实体对 $D_r = \{S_r, Q_r\}$,其中 $Q_r = \{h_m, t_m / C_{h_m, r}\}$, t_m 表示查询集中正确的尾实体, $C_{h_m, r}$ 为候选实体集,每一个候选实体都是在实体类型限制^[17]下从实体集 \mathcal{E} 中挑选出来的。在给出参考集 S_r 和查询三元组 $(h, r, ?)$ 后,通过度量函数对候选实体集 $C_{h_m, r}$ 中的每个实体打分,然后将分数排序来对模型进行训练。所有元训练任务的实体对组成元训练数据集 $T_{\text{tr}} = \{D_r\}$,并且只考虑实体集 \mathcal{E} 中存在的实体。

在元训练阶段完成之后,在元测试集中预测知识图谱中任意两个实体间是否存在新的关系 $r' \in \mathbf{R}'$,其中 r' 是在元训练任务中不可见的,即 $R' \cup R = \emptyset$ 。每个测试任务关系同样包含参考集和测试集 $D_{r'} = \{S_{r'}, Q_{r'}\}$,以与元训练集相同的方式定义。所有的测试任务构成元测试集 $T_{\text{te}} = \{D_{r'}\}$ 。此外,假设模型可以接触到所有实体的一跳邻居,即存在背景图 G' ,它是 G 的一个子集,包含除了 T_{tr} 和 T_{te} 任务关系之外的所有关系,以及所有实体。

3.2 整体框架

ACMN 由共性邻居感知编码器、任务相关实体编码器、自注意力实体对编码器和上下文关系编码器 4 个部分组成,模型框架如图 1 所示。

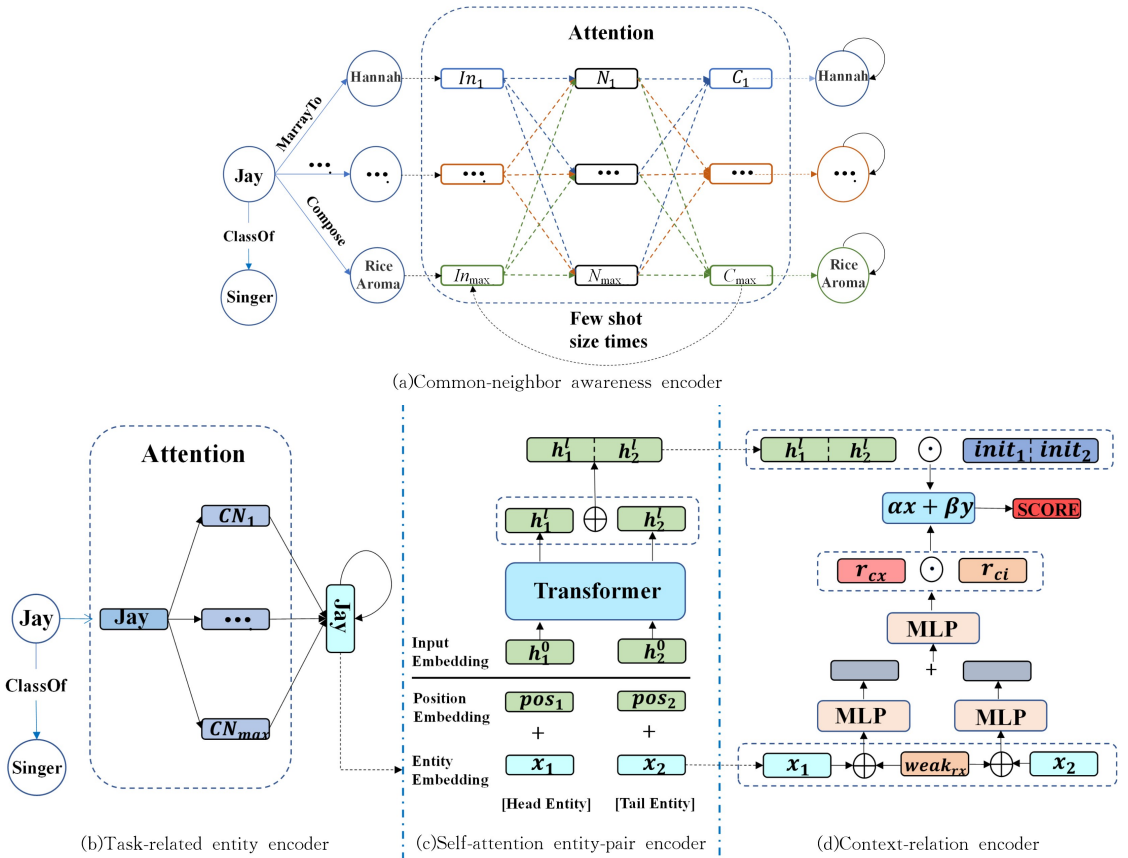


图 1 ACMN 模型框架图

Fig.1 Framework of ACMN

ACMN 包括以下 5 个步骤:

1) 共性邻居感知编码器:通过注意力机制聚合参考集实体对的上下文,即一跳邻居,获得共性邻居感知嵌入,用于任务相关实体编码器。

2) 任务相关实体编码器:捕获查询实体上下文和共性邻居上下文的相似度信息和查询实体上下文的任务相关信息,得到任务相关实体表征。

3) 自注意力实体对编码器:通过一个 Transformer 编码

器^[38]挖掘任务相关实体对的自注意力信息,获得自注意力实体对表征。

4)上下文关系编码器:基于翻译机制,根据任务关系的上下文,即头尾实体对,对任务关系进行编码,获得上下文关系表征。

5)将查询实体对的初始表征拼接后与自注意力实体对表征做缩放点积进行打分,基于翻译机制的初始关系表征与上下文关系表征也进行缩放点积操作来打分,并对两者进行加权求和以综合评价查询三元组成立的程度。

3.3 共性邻居感知编码器

对于当前的小样本知识图谱补全任务,我们提出从查询实体对与参考集实体对的上下文相似度和关系匹配程度两个方面来判断查询实体对成立的概率。其中,为了获得实体对的上下文相似性,我们提出了一个共性邻居感知编码器,对参考集中的多条实体对的上下文进行聚合,捕获不同上下文的相似性和共性特征,获得一组实体对的共性邻居感知编码。具体而言,对于当前任务中关系 r 的实体集中的每一个实体 e ,将其在背景图 G' 中的一跳邻居表示为 $N_h = \{(e_{nbr}) | (e, r_{nbr}, e_{nbr}) \in G'\}$ 。其中 e_{nbr} 表示邻居实体。共性邻居感知编码器如图 1(a)所示,其中 ClassOf 是当前任务关系, Jay 是参考集实体,其他实体如 Hannah 以及 Rice Aroma 是 Jay 在背景图中的一跳邻居,图中省略号...代表 Jay 其余的所有一跳邻居。为了捕获参考集中两两实体对的一跳邻居之间的注意力信息,我们首先选取一跳邻居数最少的实体的一跳邻居作为输入 e_{in} ,通过一个度量函数:

$$\varphi(e_{in}, e_r) = e_{in}^T W e_r + b \quad (1)$$

用双线性点积来分别计算它们与参考集中随机选择的另一个实体的一跳邻居 e_r 的相似度得分。其中, $W \in \mathbf{R}^{d \times d}$ 和 $b \in \mathbf{R}^d$ 是可学习参数。头尾实体的邻居分别,即头实体的邻居和头实体的邻居计算度量函数以及尾实体的邻居和尾实体的邻居计算度量函数。然后,针对每个邻居 e_{in} 计算它与另一个实体的一跳邻居的感知嵌入。

$$c_{out} = \sum_{e_r \in N_h} \alpha_r e_r \quad (2)$$

其中

$$\alpha_r = \frac{\exp(\varphi(e_{in}, e_r))}{\sum_{e_{rj} \in N_h} \exp(\varphi(e_{in}, e_{rj}))} \quad (3)$$

其中, c_{out} 的数量与 e_{in} 的数量一致。邻居实体 e_{in} 与 e_r 越相似, $\varphi(e_{in}, e_r)$ 越大,因此得到的邻居感知嵌入 c_{out} 包含了输入实体邻居与另一个实体一跳邻居的注意力信息。为了保留输入邻居实体 e_{in} 的信息,将 e_{in} 与邻居感知嵌入 c_{out} 进行非线性耦合,获得两实体间的共性邻居嵌入。

$$f(e) = \sigma(W_1 e_{in} + W_2 c_{out}) \quad (4)$$

其中, $\sigma(\cdot)$ 表示激活函数,本文使用 relu 函数, $W_1, W_2 \in \mathbf{R}^{d \times d}$ 是可训练参数。

最后,将得到的所有 $f(e)$ 作为新的输入实体邻居嵌入 e_{in} ,分别与参考集中剩下的实体的一跳邻居循环进行以上计算,直到聚合完所有参考集实体对的上下文,最终获得的 $f(e)$ 作为共性邻居感知嵌入,包含了参考集中所有实体对上下文间的共性特征。

3.4 任务相关实体编码器

在获得共性邻居感知嵌入后,本文提出了一个任务相关实体编码器,用于捕获查询实体上下文和共性邻居上下文的相似性信息并区分查询实体不同的一跳邻居对于当前任务的贡献程度,得到任务相关实体表征。任务相关实体编码器如图 1(b)所示,针对当前任务关系 ClassOf,对每一对查询实体对的头尾实体进行任务相关编码。以实体 Jay 为例,对于当前任务 ClassOf 而言,歌曲《Rice Aroma》相比妻子 Hannah 对当前任务的贡献显然更大。因此,首先将 Jay 的一跳邻居作为 e_{in} ,通过共性邻居感知编码器捕获 Jay 的一跳邻居与上一步获得的共性邻居感知嵌入的相似性信息,得到包含两者共性特征的嵌入 $C_h = \{cn_1, cn_2, \dots, cn_{max}\}$,图中省略号...表示除 cn_1, cn_{max} 以外的共性特征嵌入。嵌入的数量与 Jay 的一跳邻居数一致。然后,使用一个注意力机制来区分不同的一跳邻居对当前实体初始嵌入 e 的贡献程度,获得实体 Jay 的邻居感知嵌入。

$$c_{query} = \sum_{cn_i \in C_h} \beta_i cn_i \quad (5)$$

其中

$$\beta_i = \frac{\exp(\varphi(e, cn_i))}{\sum_{cn_j \in C_h} \exp(\varphi(e, cn_j))} \quad (6)$$

使用残差连接防止梯度消失,最终获得查询实体的任务相关实体编码。

$$x = e + c_{query} \quad (7)$$

3.5 自注意力实体对编码器

通过任务相关实体编码器获得查询集实体嵌入后,对于每个实体对,我们提出一个自注意力实体对编码器来增强实体对表征。如图 1(c)所示,将每个实体对作为 Transformer 编码器的输入序列 $\mathbf{X} = (x_1, x_2)$,Transformer 编码器采用多头自注意力机制,允许模型在不同的表示子空间里挖掘信息。 x_1 和 x_2 分别表示头尾实体,因为头尾实体序列包含顺序信息,所以需要为每个实体增加位置编码来向模型提供实体的位置信息。

$$h_i^0 = x_i^{ele} + x_i^{pos}, i = 1, 2 \quad (8)$$

其中, x_i^{ele} 和 x_i^{pos} 分别代表实体和位置编码。在获得包含位置信息的实体编码之后,将其输入 Transformer Blocks 来为实体对增加自注意力信息。

$$(h_1^l, h_2^l) = \text{Transformer}((h_1^{l-1}, h_2^{l-1})) \quad (9)$$

其中, $l = 1, 2, 3, \dots, L$ 。

经过 l 层 Transformer Blocks 处理后的 (h_1^l, h_2^l) 即为增强后的实体对序列,其包含了头尾实体在当前任务下的交互信息,从而有助于识别不同实体对相对于当前任务的细粒度语义。最后,把实体对序列表征拼接起来,获得实体对表征。

$$p = h_1^l \oplus h_2^l \quad (10)$$

其中, \oplus 表示拼接操作, $p \in \mathbf{R}^{2d}$ 。同样,为了保留查询实体对的初始嵌入信息,将查询头尾实体的初始嵌入拼接后,使用式(4)将其与增强后的实体对表征 p 进行非线性耦合,最终获得自注意力实体对编码 q 。

3.6 上下文关系编码器

给出一条查询实体对,要判断两个实体间是否满足当前任务关系,除了判断它们的上下文是否与参考集实体对的

上下文相似,还应该从关系角度判断相似性。例如:对于 ClassOf 这个任务关系, [Jay, ClassOf, Singer] 和 [Vincent, NotClassOf, Singer] 这两条三元组的实体对上下文可能是很相似的,但是实体对间的实际关系却是完全相反的,因此我们提出一个上下文关系编码器,用增强后的头尾实体来获得包含上下文信息的动态关系表征。如图 1(d)所示,首先基于翻译模型,将任务关系建模为头尾实体之间的转换,将其表示为:

$$weak_r = x_2 - x_1 \quad (11)$$

其中, x_1 和 x_2 是由式(9)获得的查询实体对的任务相关头尾实体编码。

然后,给定一个关系三元组 $(x_1, weak_r, x_2)$, 将头尾实体作为关系的上下文,将 $weak_r$ 和 x_1 拼接起来作为输入,并将其提供给一个多层感知机 MLP,以得到一个组合表示。 $weak_r$ 和 x_2 以相同的方式编码。最后,使用另一个 MLP 来聚合它们。这 3 个 MLP 捕获了关系和头尾实体的非线性组合特征。设 $MLP(\cdot)$ 表示一个 MLP。用以下方法得到增强后的上下文关系嵌入:

$$r_c = MLP_3(M_1 + M_2) \quad (12)$$

其中

$$M_1 = MLP_1(weak_r \oplus x_1)$$

$$M_2 = MLP_2(weak_r \oplus x_2)$$

其中, $r_c \in R^d$ 。

3.7 打分函数

最后,我们定义了一个打分函数 $\mathcal{O}(e_1, e_2, q, r_c)$, 从实体上下文相似性和关系的匹配程度两个方面综合衡量查询实体对 q_r 和参考集 S_r 的语义相似度。

$$\mathcal{O}(e_1, e_2, q, r_c) = \alpha \times A + \beta \times B \quad (13)$$

其中

$$A = (e_1 \oplus e_2) \cdot q$$

$$B = (e_2 - e_1) \cdot r_c$$

其中, e_1 和 e_2 分别为查询头尾实体的初始嵌入, $0 \leq \alpha, \beta \leq 1$, 为预设超参数,分别作为实体上下文相似度 A 和关系匹配程度 B 的权重, $\alpha + \beta = 1$ 。我们希望当 q_r 和 S_r 越相似, $\mathcal{O}(\cdot)$ 的值越大,反之,当 q_r 和 S_r 的语义相似度越小, $\mathcal{O}(\cdot)$ 的值越小。

3.8 模型训练

首先构建元训练数据集 T_{mtr} , 用于训练 ACMN。 T_{mtr} 的构建方法如下:对于每一条任务关系,随机从包含该关系的所有正向实体对集中抽取 K 个实体对作为参考集 $S_r = \{(h_k, r, t_k)\}$, 剩余的所有正向实体对作为正向查询实体对集合 $Q_r = \{(h_m, t_m) \mid (h_m, r, t_m) \in T \setminus (h_k, r, t_k)\}$ 。同时,通过从实体集中随机抽取实体 $t_m^- \in \epsilon \setminus \{t_m\}$ 的方式来构建负向实体对集合 $Q_r^- = \{(h_m, t_m^-)\}$ 。然后设计了如下的损失函数:

$$L = \sum_r \sum_{q_r \in Q_r} \sum_{q_r^- \in Q_r^-} [\gamma + \mathcal{O}(q_r^-, S_r) - \mathcal{O}(q_r, S_r)]_+ \quad (14)$$

其中, $[x]_+ = \max(0, x)$ 是一个标准 hinge 损失函数, γ 是我们期望的正向查询与负向查询的得分差,通过最小化 L 使得正向查询与参考集的语义相似度得分尽量高,负向查询与参考集的语义相似度得分尽量低,并且两者的分差值保持在一个合理的距离 γ 。

4 实验

为了验证 ACMN 模型的有效性,我们在两个公共数据集上,将本文模型与其他 8 种知名算法在不同的性能指标下进行了比较,同时也讨论了核心参数和各子模块对实验结果的影响。

4.1 数据集

本文在两个公共基准数据集 NELL^[39] 和 Wiki^[40] 上进行实验。在两个数据集中,具有相同关系的三元组被选出用于构建小样本链路预测任务,具有同种关系的实体对数量在 50~500 之间。对于 NELL 和 Wiki,分别构建 67 和 183 个任务,使用 51/5/11 和 133/16/34 的比例划分训练/验证/测试集。此外,对于每种任务关系,这两个数据集还提供了候选实体,这些候选实体基于实体类型约束^[17] 获取。数据集具体统计参数如表 1 所列。

表 1 数据集统计信息

Table 1 Statistics of datasets

Dataset	# Ent.	# Rel.	# Triples.	# Tasks.
NELL	68 545	358	181 109	67
Wiki	4 838 244	822	5 859 240	183

注: # Ent. 表示互不相同的实体数量, # Rel. 表示互不相同的关系数量, # Triples. 表示三元组数量, # Tasks. 表示从关系集中挑选作为小样本任务关系的数量。

4.2 对比算法

本文通过两类对比算法来评估 ACMN 的有效性:一类是基于嵌入的知识图谱补全方法,另一类是小样本关系学习方法。前者通过对知识图谱中的关系结构进行建模来学习实体和关系嵌入。对于前者,采用 5 个广泛使用的方法作为对比算法,分别是 TransE^[13], DistMul^[41], ComplEx^[21], SimpleE^[42] 和 RotatE^[43]。这类方法需要为每种任务关系提供足够的三元组,才能学习到实体和关系的静态表征。对于后者,采用 3 种小样本关系学习模型作为对比算法,分别为 GMatching^[17], FSRL^[18], MetaR^[44]。这类方法能在小样本的场景下得到更好的补全效果,特别地,在 NELL 和 Wiki 数据集上是当前的 SOTA 结果。

4.3 评估指标

我们给测试集中每个三元组的得分排名,并以正向三元组的排名的高低来评价补全效果的好坏。因此,使用两个评估指标 Hits@N 和 MRR 来评估所有方法在 NELL 和 Wiki 上的补全性能。其中 Hits@N 是正向三元组排名在前 N 位的任务数量占总任务数的比例, $N=1, 5, 10$ 。MRR 则是平均倒数排名。

4.4 实验设置

对 ACMN 和所有对比算法进行小样本知识图谱补全实验,参考集大小 $K=5$ 。基于嵌入的知识图谱补全对比算法是基于文献^[45]以及原始文献中报告的最佳超参数来进行实验的。在训练过程中,背景图 G' 中的一跳邻居、训练集 T_{mtr} 被用来训练模型。对于小样本关系学习对比算法中的 GMatching,通过 3 种方式将 GMatching 从原来的单样本 ($K=1$) 设定扩展到了小样本 ($K=5$) 的设定,前两种方式是通过参考集中的实体嵌入进行平均和最大池化操作来获得参考集

表征(表示为 MeanP/MaxP),第三种方式采用与查询实体对相似度得分最大的实体对作为参考集表征(表示为 MaxS)。直接采用 MetaR 和 FSRL 的原始结果来进行对比,包括预训练的嵌入,避免了重新实现模型产生的偏差。

使用 TransE 来初始化所有小样本学习对比算法的实体和关系表征。在模型训练前,随机选择实体在背景图 G' 中的一跳邻居(包括关系和实体),并固定每个实体的邻居个数为 50。对于 ACMN,设定 NELL/Wiki 的嵌入维度均为 100,自注意力实体对编码器中的 Transformer 编码器层数为 3/4,头数为 4/8。使用 dropout 来避免过拟合,在自注意力实体对编码器中的 Transformer 块中设为 0.3,非线性耦合后设为 0.1,上下文关系编码的 MLP 中设为 0.3, L_2 正则化系数均设为 1×10^{-4} 。打分函数 \mathcal{O} 中的权重 α 和 β 分别设为 0.3 和 0.7,损失函数中的正负样例距离参数 γ 固定为 5。使用 Adam

优化器,在初始的 10000 训练轮次中进行学习率预热,在之后的轮次中性衰减。每 10000 个训练轮次后在验证集上对所有的方法进行评估,并在 30000 个训练轮次内选择验证集上 MRR 最高的模型进行测试。最佳超参数是在验证集上通过网络搜索来调整的。

4.5 链路预测对比结果

表 2 列出了 NELL 和 Wiki 两个数据集上所有模型的链路预测结果。可以看出:

1) ACMN 在所有指标上都优于传统的知识图谱嵌入模型,表明了该模型的有效性。

2) 与小样本关系学习模型相比,ACMN 在两个数据集的所有指标上都有所提升。表明了从实体上下文相似度和关系匹配程度两个方面综合评价三元组成立程度的重要性,并且能够在小样本的场景下,表现出更好的性能。

表 2 NELL 和 Wiki 的 5-shot 链路预测结果

Table 2 5-shot link prediction results on NELL and Wiki

	NELL				Wiki			
	MRR	Hits@10	Hits@5	Hits@1	MRR	Hits@10	Hits@5	Hits@1
TransE	0.174	0.313	0.231	0.101	0.133	0.187	0.157	0.100
DisMult	0.200	0.311	0.251	0.137	0.071	0.151	0.099	0.024
ComplEx	0.184	0.297	0.229	0.118	0.080	0.181	0.122	0.032
disMult	0.158	0.285	0.226	0.097	0.093	0.180	0.128	0.043
RotatE	0.176	0.329	0.247	0.101	0.049	0.090	0.064	0.026
GMatching(maxP)	0.176	0.294	0.233	0.113	0.263	0.387	0.337	0.197
GMatching(meanP)	0.141	0.272	0.201	0.080	0.254	0.374	0.314	0.193
GMatching(maxS)	0.147	0.244	0.197	0.090	0.245	0.372	0.295	0.185
FSRL	0.153	0.319	0.212	0.073	0.158	0.287	0.206	0.097
MetaR	0.209	0.355	0.280	0.141	0.323	0.418	0.385	0.270
ACMN	0.284	0.411	0.344	0.213	0.349	0.463	0.382	0.295

调整参考集的大小 K 以讨论在不同的参考集大小下 ACMN 的性能表现,选择小样本关系学习模型作为比较模型,并在 NELL 数据集上进行测试,结果如图 2 所示。





图 2 NELL 上 K -shot 链路预测结果

Fig. 2 Illustration of K -shot KG completion results on NELL

1) 即使在不同的参考集大小下 ACMN 仍然可以获得

最佳的 MRR 和 Hits@10 指标表现,进一步证明了 ACMN 对于解决小样本知识图谱补全的问题的有效性。

2) ACMN 在不同的参考集大小下性能表现较为稳定,在 K 很小($K=2,3$)时,仍能取得优异的表现,体现了 ACMN 具有较强的鲁棒性和在小样本场景下的优越性能。但是,随着 K 的增大,模型性能并不一定会提升,这可能是因为在小样本场景下模型对参考集不敏感。当参考集中的实体对增加,但是共性邻居的信息没有相应增加,即 $K=2$ 和 $K=5$ 时所获得的共性邻居信息可能差别不大。

4.6 消融实验

本文对 ACMN 进行了消融实验,以进一步证明 ACMN 的各个模块都有助于提升模型的整体性能,并区分不同模块的贡献大小。表 3 列出了 ACMN 不同变体对于子模块的结合情况,表中 a,b,c,d 分别代表共性邻居感知编码器、任务相关实体编码器、自注意力实体对编码器和上下文关系编码器。通过对不同子模块进行删减和更新来构成不同的变体,其中勾选项表示该子模块保留,不做任何修改;非勾选项表示对该子模块做了相应的修改或删除,以探讨该子模块的作用和有效性。ACMN 消融实验结果如表 4 所列。从表 3、表 4 中可以看出:

1) a 部分研究共性邻居感知编码器的有效性。首先,使用取均值的方式聚合参考集实体的一跳邻居,即对参考集中头实体邻居和头实体邻居,以及尾实体邻居和尾实体邻居的

初始向量取均值,来获得共性邻居感知嵌入,每个实体随机抽取参考集实体中最小邻居数量的一跳邻居用于聚合,以形成变体 AS_a1。然后,不对由共性邻居感知编码器获得的一跳邻居的感知嵌入进行非线性耦合操作,即不计算式(4),将邻居感知嵌入 c_{out} 作为共性邻居感知嵌入,构成变体 AS_a2。实验结果表明,使用共性邻居感知编码器来聚合参考集实体的一跳邻居实体,捕获不同上下文的相似性和共性特征,可以提升模型的性能。同时,使用非线性耦合操作保留初始邻居嵌入信息是不可缺少的一步。

2)b部分研究任务相关实体编码器的有效性。首先,用取均值的方式来获得查询实体的邻居感知嵌入 c_{query} ,记录为变体 AS_b1。其次,使用 FSRL 中的基于注意力机制的方法来代替该模块,并记录为变体 AS_b2。实验结果表明,任务相关实体编码器通过捕获查询实体上下文和共性邻居上下文的相似性信息并区分查询实体不同的一跳邻居对于当前任务的贡献程度,能够提升模型的性能。

3)c部分研究自注意力实体对编码器的有效性。首先,用一个拼接操作替换该编码器,记录为变体 AS_c1。其次,去掉自注意力对编码器的位置嵌入,并记录为变体 AS_c2。实验结果表明,使用带有位置编码的 Transformer 编码器来增强实体对表征可以提升模型的性能。

4)d部分研究上下文关系编码器的有效性。将度量函数 \mathcal{O} 中的权重 α 和 β 分别设为1和0,即不使用上下文关系编码器,记为变体 AS_d1。实验结果表明,使用增强后的头尾实体对来获得包含上下文信息的动态关系表征,同时考虑实体上下文相似度和关系匹配程度两个方面的信息,有利于提升模型的性能。

表3 不同 ACMN 变体的子模块结合统计信息

Table 3 Statistics of combination of submodules of different

ACMN variants				
a	b	c	d	Variants
a1	✓	✓	✓	AS_a1
a2	✓	✓	✓	AS_a2
✓	b1	✓	✓	AS_b1
✓	b2	✓	✓	AS_b2
✓	✓	c1	✓	AS_c1
✓	✓	c2	✓	AS_c2
✓	✓	✓	d1	AS_d1

表4 ACMN 在 NELL 上的消融实验结果

Table 4 Results of ACMN ablation experiments on NELL

Variants	MRR	Hits@10	Hits@5	Hits@1
AS_a1	0.182	0.333	0.256	0.114
AS_a2	0.212	0.321	0.257	0.158
AS_b1	0.207	0.315	0.257	0.153
AS_b2	0.192	0.323	0.231	0.132
AS_c1	0.198	0.303	0.243	0.144
AS_c2	0.233	0.383	0.307	0.156
AS_d1	0.228	0.346	0.283	0.162
Ours	0.284	0.411	0.344	0.213

实体上下文与参考集实体上下文的相似度信息,基于关系的上下文对关系进行动态编码,从实体上下文相似度和关系匹配程度两个方面综合评价三元组是否成立,在小样本场景下提高了补全效果。将来,我们计划研究动态微调方法,如 prompt 来建模小样本关系,并利用更多的上下文信息,如多模态数据来增强实体嵌入,从而进一步提升小样本知识图谱补全的准确度。

参考文献

[1] HANG T T, FENG J, LU J M. Knowledge Graph Construction Techniques: Taxonomy, Survey and Future Directions[J]. Computer Science, 2021, 48(2): 175-189.

[2] LIANG H H, GU T L, BIN C Z, et al. Combining User-end and Item-end Knowledge Graph Learning for Personalized Recommendation[J]. Computer Science, 2021, 48(5): 109-116.

[3] LIU D, LIAN J, LIU Z, et al. Reinforced anchor knowledge graph generation for news recommendation reasoning[C]// Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining. 2021: 1055-1065.

[4] GUO Q, ZHUANG F, QIN C, et al. A survey on knowledge graph-based recommender systems[J]. IEEE Transactions on Knowledge and Data Engineering, 2020, 34(8): 3549-3568.

[5] ZHANG Y, QIAN S S, FANG Q, et al. Multi-Modal Knowledge-Aware Attention Network for Question Answering[J]. Journal of Computer Research and Development, 2020, 57(5): 1037-1045.

[6] BOSSELUT A, LE BRAS R, CHOI Y. Dynamic Neuro-Symbolic Knowledge Graph Construction for Zero-shot Commonsense Question Answering[C]// AAAI. 2021: 4923-4931.

[7] 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.

[8] WANG Y, XU X, HONG Q, et al. Top-k star queries on knowledge graphs through semantic-aware bounding match scores [J]. Knowledge-Based Systems, 2021, 213: 106655.

[9] WANG Q, JI Y, HAO Y, et al. GRL: Knowledge graph completion with GAN-based reinforcement learning [J]. Knowledge-Based Systems, 2020, 209: 106421.

[10] SHAO P, ZHANG D, YANG G, et al. Tucker decomposition-based temporal knowledge graph completion [J]. Knowledge-Based Systems, 2022, 238: 107841.

[11] FENG J, WEI Q, CUI J, et al. Novel translation knowledge graph completion model based on 2D convolution [J]. Applied Intelligence, 2022, 52(3): 3266-3275.

[12] HUANG J, LU T, ZHU J, et al. Multi-relational knowledge graph completion method with local information fusion [J]. Applied Intelligence, 2022, 52(7): 7985-7994.

[13] BORDES A, USUNIER N, GARCIA-DURAN A, et al. Translating embeddings for modeling multi-relational data [C]// Proceedings of the 26th International Conference on Neural Infor-

结束语 本文提出了一个自适应上下文匹配网络 ACMN,用于解决小样本知识图谱补全问题。ACMN 挖掘任务

- mation Processing Systems. Lake Tahoe, Nevada, 2013; 2787-2795.
- [14] WANG Z, ZHANG J, FENG J, et al. Knowledge graph embedding by translating on hyperplanes[C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2014.
- [15] LIN Y, LIU Z, SUN M, et al. Learning entity and relation embeddings for knowledge graph completion[C] // Twenty-ninth AAAI Conference on Artificial Intelligence. 2015.
- [16] SUN Z, HUANG J, HU W, et al. Transedge: Translating relation-contextualized embeddings for knowledge graphs[C] // The Semantic Web-ISWC 2019: 18th International Semantic Web Conference, Auckland, New Zealand, October 26-30, 2019, Proceedings, Part I 18. Springer International Publishing, 2019; 612-629.
- [17] XIONG W, YU M, CHANG S, et al. One-Shot Relational Learning for Knowledge Graphs[C] // Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. 2018; 1980-1990.
- [18] ZHANG C, YAO H, HUANG C, et al. Few-shot knowledge graph completion[C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2020, 34(3): 3041-3048.
- [19] MIKOLOV T, SUTSKEVER I, CHEN K, et al. Distributed representations of words and phrases and their compositionality [C] // Proceedings of the 26th International Conference on Neural Information Processing Systems. Lake Tahoe, Nevada, 2013; 3111-3119.
- [20] NICKEL M, TRESP V, KRIEGEL H P. A three-way model for collective learning on multi-relational data [C] // Proceedings of the 28th International Conference on Machine Learning. 2011; 809-816.
- [21] TROUILLON T, WELBL J, RIEDEL S, et al. Complex embeddings for simple link prediction[C] // International Conference on Machine Learning. PMLR, 2016; 2071-2080.
- [22] SOCHER R, CHEN D, MANNING C D, et al. Reasoning with neural tensor networks for knowledge base completion[C] // 27th Annual Conference on Neural Information Processing Systems 2013. 2013; 926-934.
- [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. 2018; 1811-1818.
- [24] 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.
- [25] WANG W J, YU Y F. Automatic completion algorithm for missing links in knowledge graph considering data sparsity[J]. Journal of Jilin University (Engineering and Technology Edition), 2022, 52(06): 1428-1433.
- [26] WANG Y, YAO Q, KWOK J T, et al. Generalizing from a few examples: A survey on few-shot learning[J]. ACM Computing Surveys(CSUR), 2020, 53(3): 1-34.
- [27] SUNG F, YANG Y, ZHANG L, et al. Learning to compare: Relation network for few-shot learning[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018; 1199-1208.
- [28] VARTAK M, THIAGARAJAN A, MIRANDA C, et al. A meta-learning perspective on cold-start recommendations for items [C] // Proceedings of the 31st International Conference on Neural Information Processing Systems. 2017; 6907-6917.
- [29] GENG R, LI B, LI Y, et al. Induction Networks for Few-Shot Text Classification[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). 2019; 3904-3913.
- [30] DONG X, ZHU L, ZHANG D, et al. Fast parameter adaptation for few-shot image captioning and visual question answering [C] // Proceedings of the 26th ACM International Conference on Multimedia. 2018; 54-62.
- [31] KOCH G, ZEMEL R, SALAKUTDINOV R. Siamese neural networks for one-shot image recognition [C] // ICML& Deep Learning Workshop. 2015.
- [32] VINYALS O, BLUNDELL C, LILLICRAP T, et al. Matching networks for one shot learning[C] // Proceedings of the 30th International Conference on Neural Information Processing Systems. 2016; 3637-3645.
- [33] SNELL J, SWERSKY K, ZEMEL R. Prototypical networks for few-shot learning [C] // Proceedings of the 31st International Conference on Neural Information Processing Systems. 2017; 4080-4090.
- [34] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks[C] // International Conference on Machine Learning. PMLR, 2017; 1126-1135.
- [35] NICHOL A, ACHIAM J, SCHULMAN J. On first-order meta-learning algorithms[J]. arXiv: 1803. 02999, 2018.
- [36] BANSAL T, JHA R, MCCALLUM A. Learning to Few-Shot Learn Across Diverse Natural Language Classification Tasks [C] // Proceedings of the 28th International Conference on Computational Linguistics. 2020; 5108-5123.
- [37] XIANG J, MOHAMMAD H, GABRIEL C, et al. Attentive task-agnostic meta-learning for few-shot text classification [C] // Conference on Neural Information Processing Systems & Meta-Learning Workshop. 2018.
- [38] ASHISH V, NOAM S, NIKI P, et al. Attention is all you need [C] // Neural Information Processing Systems. 2017; 5998-6008.
- [39] CARLSON A, BETTERIDGE J, KISIEL B, et al. Toward an architecture for never-ending language learning[C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2010, 24(1): 1306-1313.
- [40] VRANDEČIĆ D, KRÖTZSCH M. Wikidata: a free collaborative knowledgebase[J]. Communications of the ACM, 2014, 57(10): 78-85.
- [41] YANG B, YIH S W, HE X, et al. Embedding Entities and Rela-

tions for Learning and Inference in Knowledge Bases[C]//Proceedings of the International Conference on Learning Representations, ICLR, 2015.

[42] KAZEMI S M, POOLE D. Simple embedding for link prediction in knowledge graphs[C]//Proceedings of the 32nd International Conference on Neural Information Processing Systems, 2018: 4289-4300.

[43] SUN Z Q, DENG Z H, NIE J Y, et al. Rotate: Knowledge graph embedding by relational rotation in complex space[C]//7th International Conference on Learning Representations, 2019: 6-9.

[44] CHEN M, 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), 2019: 4217-4226.

[45] HAN X, CAO S, LV X, et al. Openke: An open toolkit for

knowledge embedding[C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing: System Demonstrations, 2018: 139-144.



YANG Xuhua, born in 1971, Ph.D, professor, is a senior member of CCF (No. 17093S). His main research interests include machine learning, network science and natural language processing.



YE Lei, born in 1979, Ph.D, associate professor, is a member of CCF (No. 80067M). Her main research interests include data mining and knowledge reasoning.

(责任编辑:何杨)

CCF 走进中国电信 & 天翼云,共探算力互联网前沿技术

CCF 理事长、中国工程院院士、中国科学院计算技术研究所研究员孙凝晖,中国电信集团有限公司副总经理李峻分别为活动致辞。中国电信首席科学家、云计算研究院院长吴杰主持活动。CCF 秘书长唐卫清,CCF 副理事长、北京并行科技股份有限公司董事长陈健等以及中国电信集团有限公司科创部总经理王桂荣、天翼云科技有限公司总经理胡志强等出席活动。

CCF 一行首先参观了中国电信博物馆,了解中国电信从“半部电台”到“云监工”的发展历程,以及中国电信作为数字中国建设“国家队”的最新产品及成果。

孙凝晖在致辞中感谢中国电信对本次活动做出的精心安排,赞赏中国电信为通信事业和信息服务行业发展所做出的突出贡献,表示 CCF 高度重视与企业界的沟通交流,期待通过本次活动为双方搭建更多的合作平台,共同推动云计算等领域的科技创新,助力新一代信息基础设施高质量发展。

李峻在致辞中代表中国电信对 CCF 代表一行表示热烈欢迎,介绍了中国电信在云计算、人工智能、下一代网络基础研发等领域取得的成效,指出中国电信将持续加强与 CCF 在前沿技术研究、人才培养、行业生态领域全方位合作交流,加快推进新型数字基础设施建设,持续推进云网融合和云智一体,为数字经济发展贡献力量。

主题演讲环节中,中国电信集团有限公司科创部总经理王桂荣分享了《中国电信算力互联网的思考与实践》,介绍了算力互联网发展的背景与阶段,展示了中国电信在算力互联网领域从技术标准、技术验证、工程实践到产业引领的实践过程,并提出“找算力、用算力、聚算力”的未来发展要点。

CCF 理事、高性能计算专委会主任、上海交通大学教授管海兵分享了《超算互联网及应用》,介绍了超算互联网的重要意义、发展历程及建设愿景,详细讲解了超算互联网的服务形态和探索实践。

随后唐卫清为此次 CCF 走进企业的承办单位中国电信和讲者颁发感谢牌。

研讨环节中,CCF 副理事长、北京并行科技股份有限公司董事长陈健,CCF 常务理事、数据库专委会主任、华东师范大学教授周傲英,中国信息通信研究院云计算与大数据研究所副所长栗蔚,云公司智能边缘事业部副总经理鄢智勇、中国电信研究院云网运营技术研究所副所长陆钢及多位专家共同围绕传统计算机体系结构如何适应算力和算效提升的需求,如何解决智算对计算、存储、网络和调度提出的新要求,如何基于云网融合架构让数据发挥更大价值等算力互联互通的机遇与挑战展开深入探讨。

本次 CCF 走进企业活动由中国电信承办,CCF 多位嘉宾、中国电信相关单位负责人与专家现场参加。

据 CCF 微信公众号