

知识图谱表示学习技术综述

石昌友, 夏榕泽, 黄蔚, 韩欢, 周静

(陆军工程大学 通信士官学校, 重庆 400035)

摘要: 知识图谱表示学习, 是将知识图谱中实体与关系以低维稠密向量表示的技术, 在知识图谱驱动的人工智能研究中发挥着基础性支撑作用, 已是当下研究热点, 引起学者广泛关注, 并取得很多研究成果; 从表示学习的基本概念出发, 系统性地阐述知识图谱表示学习方法最新研究进展, 具体从算法模型的问题背景、算法模型原理、算法模型特点等方面进行详细论述; 聚焦平移模型类算法, 将模型算法细分成: 单数据空间、多数据空间、概率空间、外部信息融合等类型, 详细分析代表性模型, 并梳理各算法间演化关系, 从定量和定性两个维度归纳总结平移类算法模型; 从表示空间类型、编码模型、外部信息融合、实时知识表示学习等方面展望未来发展趋势。

关键词: 知识图谱; 知识表示学习; 平移模型

Survey of Knowledge Graph Representation Learning Technology

SHI Changyou, XIA Rongze, HUANG Wei, HAN Huan, ZHOU Jing

(Communication Sergeant School, Army Engineering University of PLA, Chongqing 400035, China)

Abstract: Knowledge graph learning is a technique in which entity and relation in knowledge graph are represented by a low dimensional dense vector, which plays a significant role in the research of knowledge graph driven artificial intelligence. It is a current research hotspot and attracts widespread attention from scholar, achieving many research results. From basic concept in knowledge representation learning, this paper systematically elaborates on the latest research progress in knowledge representation learning methods, specifically discussing the background, principle, and characteristics of algorithm models in detail. By focusing on translation-based models, the algorithms are subdivided into the types of single data space, multiple data space, probability space, and external information fusion, implementing the detailed analysis of representative models and sorting out the evolutionary relationships between various algorithms, and the translation algorithms are summarized from quantitative and qualitative dimensions. Finally, future development trends for knowledge representation learning are expected from aspects such as representation space types, encoding models, external information fusion, real-time knowledge representation learning.

Keywords: graph knowledge; knowledge representation learning; translation model

0 引言

知识获取和表示是人工智能的核心主题, 对于构建高度复杂、仿人类的人工智能系统至关重要。知识图谱技术模拟人类拥有的认知层次关系结构, 为知识表达和推理的可行性提供了基础。随着大规模知识的有效表示和知识计算技术进步, 人工智能认知有了很大的提升, 在很多的现实场景中取得不错的应用效益。机器在知识的辅助、引导下实现求解已经成为重要的解决问题手段。

知识图谱必须经过合理的表示才能被计算机处理。

知识表示是知识图谱的重要技术方向, 关乎着知识图谱巨大价值的发挥。学者们提出了知识图谱的表示学习(KRL, knowledge representation learning)课题, 已成为当下研究热点, 本质上是把知识映射到向量空间, 使得数值运算变得可操作和有意义。现有知识图谱表示学习技术相关的综述^[1-4], 普遍都是对表示学习技术进行粗略分类, 然后对各代表性算法展开总结, 没有学者对某类表示学习技术深入开展研究, 探讨模型代表性算法之间的发展脉络。本文聚焦基于平移模型的表示学习技术, 分析典型算法模型的思路、技术原理、性能特征,

收稿日期: 2024-10-16; 修回日期: 2024-12-25。

作者简介: 石昌友(1984-), 男, 硕士, 讲师。

引用格式: 石昌友, 夏榕泽, 黄蔚, 等. 知识图谱表示学习技术综述[J]. 计算机测量与控制, 2025, 33(3): 1-11, 29.

剖析各算法之间的逻辑渊源关系,以发展的观点梳理知识表示学习方法的发展脉络。

1 知识图谱

1.1 实现人工智能的基础

知识是实现人工智能的基石,尤其是实现有认知能力的人工智能,离不开知识的支撑。让机器具备人类认知世界的的能力,就是让机器获得理解和推理两个核心能力,要求机器存储类似人类理解中固有的认知层次联系,并在认知层面能实现有效的复杂编织,在场景问题中发生映射关联。推理从知识出发,按照一定规则发现隐含知识。知识图谱是大数据时代的知识工程,将世界知识组织成结构化的语义网络。有了知识图谱,机器完全可以重现仿效人类的这种理解与推理的过程。此外,知识图谱对于增强机器学习的能力有着积极意义,对人工智能模型可解释性差、难以应对开放性挑战、模型不健壮因而易于受到恶意样本攻击等方面有着巨大的潜能。因为人工智能模型有效利用大量累积的符号知识,是突破其瓶颈的重要思路。

知识图谱技术已经成为实现认知层面的人工智能不可或缺的重要技术之一,在自动化知识获取、推理、大规模图挖掘与分析等领域又取得了很多新进展,在搜索引擎、智能问答、语言理解、推荐计算、大数据决策分析等众多领域得到探索试用,例如,基于语义的搜索^[5]、机器智能问答^[6-7]、语言和文本理解^[8-9]、大数据分析^[10-11]、机器学习的可解释性增强^[12-13]、推荐系统^[14]等。

在大数据分析、智能搜索、自然人机交互、辅助决策方面,知识图谱都呈现巨大的应用前景。大数据的精准与精细分析需要知识图谱。现今业务行业界积累了规模可观的大数据,缺乏诸如知识图谱技术制约了人工智能对数据的理解,制约了大数据的价值变现。智能搜索呈现出搜索对象复杂化、多元化,搜索粒度多元化,跨媒体协同搜索等特点。传统的知识管理无法理解用户搜索意图,必须借助知识图谱提升人工智能认知水平,赋予机器一种跨媒体的协同搜索能力,也为知识型的内容推荐打下基础。自然人机交互包括自然语言问答、对话、体感交互、表情交互等,对过程的自然和简单提出了要求,越是自然、简单的交互方式越要求机器具备强大的智能,即更高的认知智能水平和更广泛的背景知识。而知识图谱就是这类背景知识的重要形式之一。知识图谱为决策支持提供深层关系发现与推理能力。应用场景越发希望发现和挖掘一些深层、潜藏的关系。因此,建立包含各种语义关联的知识图谱,挖掘实体之间的深层关系,已经成为决策分析的重要辅助手段。

1.2 知识图谱表示学习

有理解能力的人工智能,涵盖知识表示、获取、计

算和推理应用等研究课题。其中,表示学习技术旨在探索如何对不同类型知识进行组织和表示,支持计算机最大化地利用这些知识。在通过向量及其语义来表示实体和关系(例如关系)保存在向量空间中,可以推断出隐含的和新的知识,通常是通过近似或预测。

近年来,知识表示学习技术在知识图谱推理中取得了巨大的成功,特别是在没有预定义逻辑的归纳推理中,可以处理不确定性和数据噪声,并且能够预测不确定但合理的知识。可以显著提高知识图谱在许多应用中的使用率,特别是将表示学习技术用于逻辑推理相关任务,如查询回答、定理证明和规则挖掘等等。总之,知识表示对于人工智能的理解、推理中起着至关重要的作用。许多通用和特定领域的知识图谱,如维基数据和 SNOMED 临床术语,正在快速开发和广泛使用。

采用原始符号对知识图谱进行表达的方法,具有表达自然、知识结构化、可解释性强的特点,便于从人的角度观察和理解知识图谱,但是在机器的世界里,原始符号的表达方式面临巨大挑战。于是,学者们展开了大量研究。可以分成 3 大类:基于平移模型的知识表示技术、基于张量模型的知识表示技术、基于深度学习的知识表示技术。基于张量模型的知识表示技术将知识图谱看作一个三维邻接矩阵,矩阵由单位三阶张量构成,每个三元组对应矩阵中一个元素,即单位三阶张量,通过三元组对应的 3 个向量的乘积与矩阵的单位张量相近程度判定三元组是否成立。RESCAL^[15]是最早的张量分解表示学习模型,Analogy^[16]优化了张量分解模型,还改进了 DistMult 模型对关系嵌入的约束。基于深度学习的知识表示技术就是利用卷积神经网络的先进能力应用于知识表示任务。ConvE^[17]是首次使用多层卷积神经网络解决链接预测任务的模型。算法 ConvKB^[18]、ConvR^[19]在此基础上又做了进一步改进。CapsE^[20]将胶囊网络的引入知识表示学习中。CompGCN^[21]引入了图神经网络。基于平移模型的知识表示技术就是对实体和关系向量化,利用向量运算操作达成对知识的表示,研究成果有 TransE^[22]及其扩展算法系列等等。

在知识图谱表示技术综述方面,也有不少文献。Goyal 和 Ferrara^[23]分析了嵌入任务及其挑战,针对基于因子分解方法、随机游走和深度学习的 3 类表示学习技术进行了全面和结构化的分析。CAI 等人^[24]第一次从问题背景视角对知识表示学习技术进行分类。从问题场景分析了各种知识表示学习技术的原理并阐释其在对应问题场景有效的原因。Lin 等人^[25]从知识获取的 3 个评价任务:知识图谱补齐、三元组分类和关系信息提取,对几种典型的知识表示学习方法进行定量比较分析,并就知识表示学习面临的挑战和发展前景进行分析讨论。Wang 等人^[1]对现有知识表示学习技术进行了系

统回顾,描述了总体框架、具体的模型设计、典型的训练程序,以及这些技术的优缺点。Dai等人^[2]系统地介绍现有的先进的知识表示学习的方法以及从这些方法中受益的各种应用,并讨论了知识图嵌入的未来研究方向。Choudhary等人^[3]把知识表示学习分成3类:基于翻译模型、基于语义匹配模型、融合文本的信息或图像的信息的知识表示学习,分别进行综述。Gesese等人^[4]对知识表示学习模型进行综合研究,重点考查了在典型知识表示学习模型中融合非结构化信息,例如文本、数字、图像、或多信息混合的技术。

本文围绕知识图谱的知识表示学习,以递归综述的全新思路,对现有研究成果进行系统、深入地梳理与总结,主要完成了以下工作:

1) 梳理了近年来知识表示学习的研究进展,给出一份较为完整详细的相关研究清单,重点聚焦近几年的最新研究进展,并围绕最近的研究热点和研究趋势,对其中具有代表性的模型进行原理剖析。

2) 以一个全新的思路,即递归综述,归纳和梳理知识图谱表示学习技术。以一个大的视角对知识图谱表示学习技术进行分类,从分类层面对研究成果进行梳理,在每个技术分类下递归综述,对分类内的研究成果再次归纳梳理,剖析代表性的成果的原理,最终得到树型结构的梳理成果。

3) 展望了知识表示学习的未来研究方向,基于系统性地归纳和梳理,结合知识表示学习的发展演进历程,对未来工作的几个有前途的研究方向进行了全面的展望。

2 基于平移模型的知识表示

首先介绍知识表示学习中的常用符号。以符号 ϵ 表示实体集合,符号 R 表示关系集合,符号 τ 表示三元组集合。对于事实三元组,使用 (h, r, t) 进行表示,其中 h 代表头实体, r 代表尾实体, t 代表头尾实体之间的关系。根据定义,有 $h \in \epsilon, r \in R, t \in \epsilon$, 以及 $(h, r, t) \in \tau$ 。使用粗体的符号 $\mathbf{h}, \mathbf{r}, \mathbf{t}$ 表示头尾实体与关系对应的表示向量。

聚焦基于平移模型的知识图谱表示技术,对研究进展进行综述。图1详细梳理了基于平移模型的主要算法模型。从映射空间类型角度把算法模型分成四类。欧式空间类算法又进一步分成同空间和多空间两个子类。算法模型间均存在明显的演化关系,后续的章节,按照图1的分类逻辑,详细分析图1所提及的算法模型。

2.1 欧式空间的平移模型

2.1.1 同空间建模

1) TransE算法:

受到词向量表示模型中的词向量间平移现象启发,

Bordes等人^[22]在2013年提出知识表示学习算法,即平移模型(TransE),将实体和关系映射至同一个低维向量空间,采用实体向量之间的平移操作完成向量间的相似性度量,从而实现对三元组成立的置信度判定。假设知识图谱三元组 $tri = (h, r, t)$, 则评分函数定义为:

$$E(tri) = \|\mathbf{h} + \mathbf{r} - \mathbf{t}\|_{L_1/L_2} \quad (1)$$

在训练模型时采用最大间隔方法,训练优化函数定义如下:

$$L = \sum_{tri' \in \tau} \sum_{tri \in \tau} \max[\gamma + E(tri) - E(tri')] \quad (2)$$

其中: τ^-, τ^+, γ 分别表示三元组负例集合,三元组正例集合,间隔参数。通过最大化训练函数完成平移模型的训练。

向量平移的假设难以表达复杂的知识关系,其实实体间可以构成多重关系,一些关系隐含着高级语义,模型难以对这些复杂情况建模表示。

2) TransH算法:

Wang等人^[26]认识到TransE模型对平移的假设性过强,在自反关系、关系多重属性中会学习到不合理的实体向量,便放宽了模型的评分函数的约束,提出了TransH模型。算法把关系定义为某超平面的向量,首先把实体投影按照超平面的法向量投影到关系的超平面,然后对投影向量、关系的平移向量进行平移计算得分函数。评分函数定义为:

$$E(tri) = \|\mathbf{h}_\perp + \mathbf{r} - \mathbf{t}_\perp\|_{L_1/L_2} \quad (3)$$

$$\mathbf{h}_\perp = \mathbf{h} - \mathbf{W}_r^T \mathbf{h} \mathbf{W}_r, \mathbf{t}_\perp = \mathbf{t} - \mathbf{W}_r^T \mathbf{t} \mathbf{W}_r \quad (4)$$

其中: \mathbf{W}_r 表示关系超平面的法向量。TransH对关系进行初步区别,但是模型实体向量和关系向量仍然是同一个数据空间类型。

3) TransC算法:

概念知识是呈层次化结构的,实例归属于某概念,概念又归属于更抽象的父概念。一些知识表示算法很少关注概念和实例的区别,而是将它们同等地看成实体,容易导致两个问题:概念表示弱化,以及“isA”关系、“subclass”关系的传递性丢失。

针对以上问题,TransC模型^[27]将三元组知识分成3类:概念实例三元组、概念层次三元组、普通三元组。将概念编码成球体,实例编码为同一语义空间的向量。对于实例归属于概念的关系,只需计算实例向量是否位于概念的球体内即可;对于概念包含关系,只需要计算子概念的球体是否位于父概念的球体内即可。对于其它的三元组,依然按照TransE模型的算法进行处理。球体定义由圆心与半径表示。对于概念实例三元组三元组,评分函数定义为:

$$E(instance) = \|\mathbf{e} - \mathbf{cen}\|_{L_2} - rad \quad (6)$$

对于概念层次三元组,评分函数定义为:

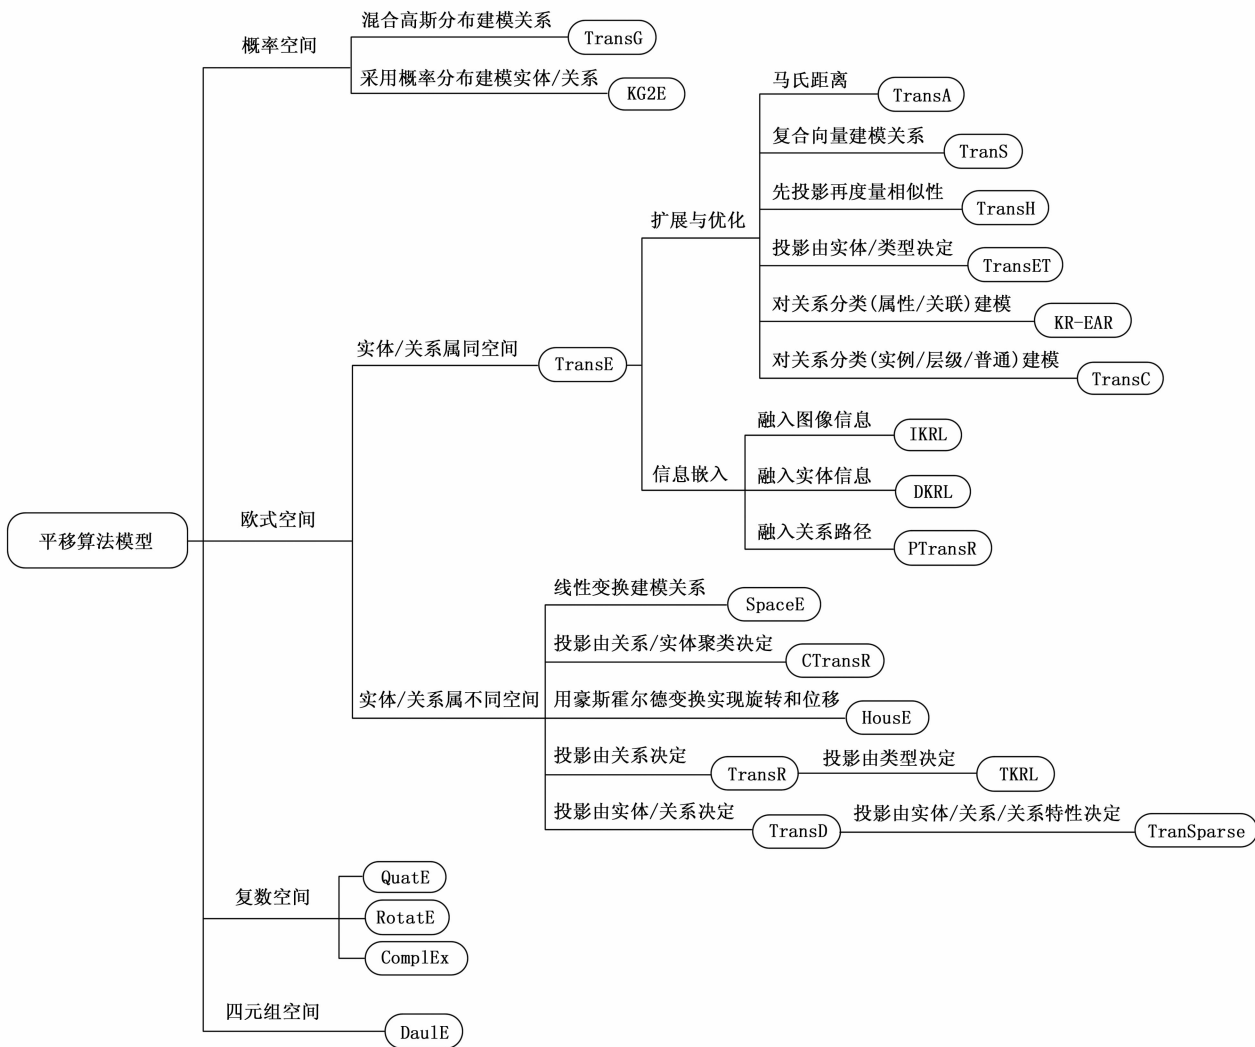


图 1 平移模型算法分类视图

$$E(\text{subclass}) = \| \text{cen}_h - \text{cen}_t \|_{L_2} + \text{rad}_h - \text{rad}_t \quad (7)$$

其中：符号 cen_h , cen_t , rad_h , rad_t , 分别表示头尾实体的球心位置向量和半径。

4) TransS 算法：

针对具有复杂关系的相同实体对情况，例如在同公司工作的一对父子，既是同事关系又是父子关系，以前的模型，例如虽然之前的模型，如 TransH/R/D 延续了 TransE 模式解决 1-to-N、N-to-1 和 N-to-N 的问题，即使实体向量由超平面或多个嵌入空间表示，当面对同一实体对时，单个关系向量表示多个的关系能力仍有局限。Zhang 等人^[28]提出了一种新的基于平移的知识图谱嵌入方法，即 TranS 模型，将传统评分模式中的单一关系向量替换为合成关系，可以有效地解决这个问题。

TranS 模型与传统模型的评分模式不同，将关系向量替换成合成关系向量，由 3 个关系向量之和组成，融合了头部和尾部实体信息。新的评分函数定义如公式 (12)：

$$E(\text{tri}) = \| \mathbf{h} \circ \bar{\mathbf{t}} - \mathbf{t} \circ \bar{\mathbf{h}} + \bar{\mathbf{r}} \circ \mathbf{h} + \mathbf{r} + \bar{\mathbf{r}} \circ \mathbf{t} \|_{L_1/L_2} \quad (12)$$

式中， \mathbf{h} , \mathbf{t} , \mathbf{r} 符号与传统平移模型中向量类似， $\bar{\mathbf{h}}$, $\bar{\mathbf{t}}$ 分别表示辅助头实体向量，辅助尾实体向量， $\bar{\mathbf{r}}$, $\bar{\mathbf{r}}$ 分别表示与头部实体相关的辅助关系向量，与尾部实体相关的辅助关系向量。两个向量之间的“圆圈”符号表示 Hadamard 乘积。

5) TransET 算法：

知识实体在不同的三元组关系中通常表现不同的语义，因为三元组的关系会约束其头、尾实体的类型，因此具有不同的嵌入向量表达，TransET 算法模型^[29]对该过程的发生机制进行了探索，提出了一种显性融合实体关系的平移模型算法。首先算法模型对实体和关系执行循环卷积操作，现在在建模实体嵌入向量的过程中充分融入类型信息。具体来说，三元组的实体、关系、类型向量都是 d 维空间的向量，头实体 h 在某关系 r 语义

下的类型使用 $type^{r,h}$ 表示, 以头实体为例, 循环卷积操作过程的形式化如下公式:

$$\hat{h}_i = \sum_{k=1}^{d-1} h_k \text{type}_{(i+k) \bmod d}^{r,h}, i = 0, 1, \dots, d-1 \quad (13)$$

即, 头实体向量与类型向量旋转后逐维度乘积再求和, 直观的视角可参见图2。图中两个圆环分别代表头实体向量和尾实体向量, 通过把向量的头尾相接起来, 构成循环向量。循环卷积的过程就是内环向量每旋转一个维度位置后, 逐维度乘积求和的过程。循环卷积让类型向量和实体向量在对应维度和非对应维度间获得充分的特征关联。

循环卷积操作后, 意味着实体向量已经在具体关系语义的约束下映射到新的向量空间, 接下来需要运用平移模型对三元组的表示向量进一步约束控制, 定义评分函数如下:

$$E(tri) = \|\hat{h} + r - \hat{t}\|_{L_1/L_2} \quad (14)$$

那么优化函数可以定义为:

$$L = \sum_{tri' \in \tau} \sum_{tri \in \tau'} \max(\gamma + E(tri) - E(tri')) \quad (15)$$

优化函数公式中相关符号的含义与 TransE 模型相同, 本质上在规定间隔值下的对正负样本分别求最大、最小相似。




图2 循环卷积过程图

6) IKRL 算法:

视觉是人类重要的认知方式, 在与外界进行信息获取与交互行为中, 很大部分是通过视觉完成。以图像形式为代表的视觉表达媒体包含着丰富的信息细节, 图像信息的有效利用, 有助于从多角度理解知识。IKRL 模型^[30], 是融合实体图像信息的知识表示学习模型, 利用实体图像编码器对实体处理, 得到各个图像在知识空间的表示, 然后融入到平移模型。IKRL 模型评分函数定义如式:

$$E(tri) = \alpha_1 \|\mathbf{h} + \mathbf{r} - \mathbf{t}\|_{L_1} + \alpha_2 \|\mathbf{h}_i + \mathbf{r} - \mathbf{t}_i\|_{L_1} + \alpha_3 \|\mathbf{h} + \mathbf{r} - \mathbf{t}_i\|_{L_1} + \alpha_4 \|\mathbf{h}_i + \mathbf{r} - \mathbf{t}_i\|_{L_1} \quad (16)$$

式中, \mathbf{h} , \mathbf{r} , \mathbf{t} , \mathbf{h}_i , \mathbf{t}_i 分别表示头实体、关系、尾实体的知识表示向量, 头实体和尾实体的图像信息描述向量。 α_1 , α_2 , α_3 , α_4 是各项权重的超参数。显然, IKRL 模型将实体的两种向量映射到了同一语义空间中, 并共

享相同的关系向量。

IKRL 模型通卷积神经网络提取实体图像的特征。在预处理过程中, 将每幅图像水平翻转得到两幅图像, 然后从中心、四角位置截取分辨率为 $224 * 224$ 的图像作为网络输入。借鉴 Shutova 等人^[31]的做法, 把 AlexNet 卷积神经网络的第二个全连接层输出的 4096 维向量作为图像特征表示。然后通过图像投影模块把图像的特征映射到实体标识向量空间, 映射公式如下:

$$\mathbf{V}_i = \mathbf{M} * \text{feature}(img_i) \quad (17)$$

式中, \mathbf{M} , $\text{feature}(\ast)$ 分别表示投影矩阵和卷积网络输出的图像特征。

一个实体对应多幅图像, 每幅图像的携带的信息侧重点各有差异。IKRL 模型提出一种基于注意的多实例学习方法完成对系列图像特征的融合。基于注意的方法可以从多个候选实例中自动选择信息实例。给定实体, 一幅图像特征的注意力计算如下:

$$\text{attr}(\mathbf{V}_i^e, \mathbf{E}) = \frac{\exp\{\mathbf{V}_i^e * \mathbf{E}\}}{\sum_{j=1}^n \exp\{\mathbf{V}_j^e * \mathbf{E}\}} \quad (18)$$

IKRL 模型以图像特征的注意力为基础, 图像特征融合按照如下公式计算:

$$\text{Fusion}(img) = \sum_{i=1}^n \frac{\text{attr}(\mathbf{V}_i^e, \mathbf{E}) * \mathbf{V}_i^e}{\sum_{j=1}^n \text{attr}(\mathbf{V}_j^e, \mathbf{E})} \quad (19)$$

式中, \mathbf{V}_i^e , \mathbf{E} 分别表示图像特征在知识空间的向量和实体表达向量。

7) PTransR 算法:

很多的平移模型往往只考虑了实体之间的直接关系, 忽略了实体间多步路径关系。知识图谱的多步路径关系蕴含着丰富的语义信息, 对知识推理、知识表示具有重要意义。有学者提出 PTransE 模型^[32], 将知识图谱中的关系路径融入知识表示学习模型中, 即在 TransE 模型基础上添加知识的路径信息。评分函数定义如下:

$$E(tri) = \|\mathbf{h}_r + \mathbf{r}_r - \mathbf{t}_r\|_{L_1/L_2} + \mathbf{G}(h, ps, t) \quad (21)$$

$$\mathbf{G}(h, ps, t) = \frac{1}{Z} \sum_{p \in ps} \mathbf{R}(p | h, t) \mathbf{G}(h, p, t) \quad (22)$$

其中:

$$Z = \sum_{p \in ps} \mathbf{R}(p | h, t)$$

$$\mathbf{R}(p | h, t) = \sum_{e1 \in pre(t)} \frac{1}{|\{e | e \in suc(e1)\}} \mathbf{R}(e1)$$

$$\mathbf{R}(h) = 1$$

(23)

式中, 使用符号 $pre(\ast)$, $suc(\ast)$ 分别表示节点的直接前驱和后继, 节点的资源计算函数 $\mathbf{R}(\ast)$ 是沿着路径递归的计算过程。

金牌由于实体对在知识图谱中可能存在多个不同的

关系路径, 各条关系路径在体现实体间联系方面的可靠性可能存在差异, 因此定义关系路径的可靠性为各关系路径下根据其可靠性加权平均的结果。路径可靠性评估算法的基本思想是, 假设一定数量的资源从头部实体沿着路径流动, 每个节点会把资源平均投入到各路径分支, 尾实体接收到的资源量就是该实体对的路径可靠性。路径向量表示有 3 种方法: 路径上的所有关系向量加和、乘积、卷积神经网络编码。以加法为例, 评分函数可以写成:

$$E(\text{tri}) = \|\mathbf{h}_r + \mathbf{r}_r - \mathbf{t}_r\|_{L_1/L_2} + \frac{1}{Z} \sum R(p|h, t) \|\mathbf{r}_r - \mathbf{p}_i\|_{L_1/L_2},$$

$$\mathbf{p}_i = \sum_{i=1} \mathbf{r}_i$$

2.1.2 多空间建模

1) TransR 算法:

TransR 模型^[33]把实体看成是多种属性的综合体, 不同关系关注实体的不同属性, 采用实体空间和关系空间分别建模实体和关系, 首先把实体投影到关系的数据空间, 然后再做向量运算。在三元组关系中, 评分函数定义为:

$$E(\text{tri}) = \|\mathbf{h} * \mathbf{M}_r + \mathbf{r} - \mathbf{t} * \mathbf{M}_r\|_{L_1/L_2} \quad (24)$$

其中: \mathbf{M}_r 表示实体向量到关系空间的投影矩阵。TransR 模型考虑到关系不同, 允许实体在涉及不同关系时具有不同的表示形式。

研究注意到相同的关系在不同实体对中的语义通常具有多样性, 在 TransR 的基础上提出了 CTransR 模型, 先利用聚类算法对头尾实体间的潜在关系进行聚类, 每种聚类使用独立向量表示。假设有某特定关系, 所有训练数据蕴含该关系的实体对会被聚类到若干组类中, 组内实体对在该关系下具有相近特征, 组间在该关系的语境下具有较大差异。因此评分函数重新定义:

$$E(\text{tri}) = \|\mathbf{h}_r + \mathbf{r}_c - \mathbf{t}_r\|_{L_1} + \alpha \|\mathbf{r}_c - \mathbf{r}\|_{L_2},$$

$$\mathbf{h}_r = \mathbf{h} * \mathbf{M}_r,$$

$$\mathbf{t}_r = \mathbf{t} * \mathbf{M}_r, \quad (25)$$

其中: \mathbf{M}_r, α 分别表示实体向量到关系空间的映射矩阵, 用于调节第 2 项损失的权系数。第 2 项损失约束聚类后的关系向量与关系在 TransR 模型中原始向量间的距离, 使其不能过分偏离原始向量。

2) TKRL 算法:

实体的层次类型信息一定程度上隐含着知识的语义。在不同的场景下, 具有多种类型的实体可能具有侧重表达某类型含义。这有助于对知识图谱的表示学习。研究者提出了 TKRL 模型^[34], 把实体层次类型信息融入平移模型, 完成知识图谱的表示。为了将层次类型信息编码到表示学习中, TKRL 模型提出了一个类型编

码方法来构造每个实体的投影矩阵:

$$\mathbf{M}_{e,r} = \frac{1}{n} (\mathbf{M}_{c,r,e,1} + \mathbf{M}_{c,r,e,2} + \dots + \mathbf{M}_{c,r,e,n}) \quad (26)$$

式中, $\mathbf{M}_{c,r,e,1}, \mathbf{M}_{c,r,e,2}, \dots, \mathbf{M}_{c,r,e,n}$, 某关系语义下实体在其对应的类型层次体系中投影矩阵。编码公式的含义是实体的投影矩阵等于各层次类型投影矩阵的数学平均和。假设某类型概念, 其在类型层次体系结构中由一个子类型体系构成, 则其投影矩阵可以通过两种方法计算:

$$\mathbf{M}_{c,r,e} = \prod_{k=1}^m \mathbf{M}_{c^{(k)},r,e} \quad (27)$$

和

$$\mathbf{M}_{c,r,e} = \sum_{k=1}^m \beta_k \mathbf{M}_{c^{(k)},r,e} \quad (28)$$

加权系数按照如下公式计算:

$$\beta_k : \beta_{(k+1)} \in (0.5, 1), \quad 1 = \sum_{k=1}^m \beta_k \quad (29)$$

加权系数的公式表明, 在类型层次体系中, 类型越抽象、高阶, 其语义抽象程度高, 在投影矩阵构造时贡献越小, 相反, 低级水平的类型, 其指向性更加明确, 应该给予更高的权重。最终 TKRL 模型的评分函数为:

$$E(\text{tri}) = \|\mathbf{M}_{h,r} \mathbf{h} + \mathbf{r}_r - \mathbf{M}_{t,r} \mathbf{t}\|_{L_1} \quad (30)$$

从式中可知, TKRL 模型与 TransR 模型非常类似, 区别就是 TKRL 模型的投影矩阵融合了实体所属类型层次信息。

3) TransD 算法:

TransR 模型将实体和关系在不同的向量空间中表示, 利用复杂矩阵计算将实体映射到关系向量空间, 然后再度量相似性。考虑到实体类型差异比较大, 所有实体不加区分地运用相同的投影过程不太合理。知识的表达应该同时考虑关系和实体的多样性情况。在 TransD 模型^[35]中, 每个对象 (实体和关系) 由两个向量表示, 给定三元组, 它的向量表示为 $[(\mathbf{h}, \mathbf{h}_p), (\mathbf{r}, \mathbf{r}_p), (\mathbf{t}, \mathbf{t}_p)]$, 不带下标的分量表达实体 (关系) 的含义, 带下标的分量服务于构造映射矩阵。TransD 模型的评分函数定义如下:

$$E(\text{tri}) = \|\mathbf{h}_\perp + \mathbf{r} - \mathbf{t}_\perp\|_{L_1/L_2} \quad (31)$$

$$\mathbf{h}_\perp = \mathbf{h} * (\mathbf{r}_p^T \mathbf{h}_p + \mathbf{I})$$

$$\mathbf{t}_\perp = \mathbf{t} * (\mathbf{r}_p^T \mathbf{t}_p + \mathbf{I}) \quad (32)$$

其中: \mathbf{I} 为单位矩阵, 用于初始化每个映射矩阵。因此, 映射矩阵是由实体和关系共同决定的, 这种操作使两个投影向量充分交互。

4) SpaceE 算法:

在知识图谱中, 普遍存在着多对一、一对多、多对多的关系。基于平移模型的算法通过位移或旋转操作不能很好地建模。Yu 等人^[36]提出了 SpaceE 算法模型, 将三元组的关系建模为一种线性变换, 并从理论上证明了 SpaceE 能够支持多种关系模式, 包括对称性、斜对

称性、反演、阿贝尔合成和非阿贝尔组合。

算法的主要思想是: 两个实体如果存在某个关系, 那么就对应于两个实体矩阵间存在一个线性变换。相反, 如果不构成关系知识, 对头实体线性变换的结果向量会偏离尾实体向量。形式化定义:

$$E(\text{tri}) = \| \mathbf{HR} - \mathbf{T} \|_F, \quad (35)$$

$$\mathbf{H}, \mathbf{T} \in \mathbf{A}_{p \times q}, \mathbf{R} \in \mathbf{A}_{q \times q},$$

$\| * \|_F$ is Frobenius norm of a matrix

对于互逆关系来说, 可以定义成:

$$E(\text{tri})^* = \| \hat{\mathbf{R}} - \mathbf{H} \|_F \quad (36)$$

式中, \mathbf{H} , \mathbf{T} , \mathbf{R} , $\hat{\mathbf{R}}$ 分别表示头实体、尾实体的矩阵、某关系对应的线性变换方阵、逆反关系对应的线性变换方阵。使用以上两个公式分别预测头实体和尾实体, 当变换矩阵为奇异矩阵时, 算法具备多对一、一对多关系的建模能力。算法最终学习优化函数定义如下:

$$L = -\log\{\text{sig}(\gamma - E(\text{tri}))\} - \log\{\text{sig}(\gamma - E(\text{tri})^*)\} - \sum_{i=1}^k p(\bar{h}_i, r, t) \log\{\text{sig}(E(\bar{h}_i, r, t) - \gamma)\} - \sum_{i=1}^k p(h, r, \bar{t}_i) \log\{\text{sig}(E(h, r, \bar{t}_i)^* - \gamma)\} \quad (37)$$

式中, $\text{sig}(*), p(*), \gamma$ 分别表示 sigmoid 函数, 样本权重、固定间距。

5) HousE 算法:

Li 等人^[37] 从知识图谱的关系模式 (relation pattern) 和关系映射属性两个维度切入, 提出 HousE 模型, 对知识图谱中重要的关系模式: 对称关系、非对称关系、互逆关系、组合关系和关系的映射属性: 一对一关系、一对多关系、多对一关系和多对多关系都有很好的建模效果。

HousE 模型引入 Householder 反射变换作为基本数学工具, 并基于此设计了两种线性变换: Householder 旋转和 Householder 投影。从几何上来看, Householder 矩阵用于描述关于一个 (过原点) 超平面的基本反射变换, 能够对某向量做关于以另外一个单位法向量的超平面的镜面反射。给定 $2n$ 个单位向量, 定义如下映射公式:

$$\text{RotH}(U) = \prod_{i=1}^{2n} \mathbf{H}(\mathbf{u}_i), \mathbf{u}_i \in R^k \quad (38)$$

式中, $\mathbf{u}_i, \mathbf{H}(*)$ 分别表示单位向量系列和基于以某单位向量为法向量的 Householder 矩阵。该研究从理论上证明了当 $n = \lfloor k/2 \rfloor$ 时, 任意 $k \times k$ 的旋转矩阵都可以通过该映射公式计算得到。例如任意二维空间中的旋转都可以分解为横向和纵向两个基本反射。通过 Householder 反射组合而成的旋转称为 Householder 旋转。该研究从数学上证明了 Householder 旋转可以支持对称、反对称、逆对称、组合等关系模式。仅靠旋转无法有效地处理知识图谱中复杂的关系映射属性 (一对多、多对

一和多对多), 例如在一对多关系中, 位于“多”端的不同实体可能会得到相同的嵌入向量。受到前人 TransSH^[26]、TransR^[33] 的启发, HousE 模型对原始的 Householder 矩阵进行修改, 提出了一种新的可逆投影, 称为 Householder 投影, 来建模映射属性。具体说来, 给定一个单位向量 \mathbf{u} 和一个实数 a , Householder 反射改造为:

$$\mathbf{M}(\mathbf{u}, a) = \mathbf{I} - a * \mathbf{u}\mathbf{u}^T, \mathbf{u} \in R^k \quad (39)$$

当实数不等于 1 时, 矩阵总是可逆的, 从几何上分析, 该反射矩阵能对向量做沿着向量 \mathbf{u} 轴投影变换。实数决定了投影位置。给定一组单位向量和一组实数, 定义投影映射:

$$\text{PotH}(U, A) = \prod_{i=1}^m \mathbf{M}(\mathbf{u}_i, a_i), \mathbf{u}_i \in R^k, a_i \in R \quad (40)$$

由于可逆矩阵的乘积仍然是可逆矩阵, 因此上述映射的输出也是一个可逆矩阵, 对应的投影变换同样是可逆的。这种由修改后的 Householder 反射组合而成的可逆投影称为 Householder 投影。

将所设计的 Householder 旋转与 Householder 投影, 纳入统一的框架得到 HousE 模型。对于知识图谱三元组, HousE 首先通过 Householder 投影对头尾实体进行变换, 得到与具体关系相关的头尾实体投影向量, 然后对头实体的投影向量施行 Householder 旋转, 向尾实体的投影向量靠近。算法的评分函数为:

$$E(\text{tri}) = \| \text{RotH}(*)\mathbf{h}_r - \mathbf{t}_r \|_{L_2}, \quad (41)$$

$$\mathbf{h}_r = \text{PotH}(*)\mathbf{h},$$

$$\mathbf{t}_r = \text{PotH}(*)\mathbf{t}$$

得益于投影的可逆性和旋转的可扩展性, HousE 能够全面有效地建模常见的关系模式和映射属性, 并且可以视为现有旋转模型的推广。

2.2 概率空间的平移模型

1) TransG 算法:

KG2E 模型^[38] 首次从非确定性的视角审视知识表示, 受该研究的启发, TransG 模型^[39] 围绕关系的多重语义问题进行建模。知识图谱中的一种关系具有多重语义, 在一个三元组中表现何种语义与关系链接的头、尾实体有关, 于是 TransG 模型采用高斯混合模型进行建模。将每种语义以一个高斯分布进行刻画, 一个关系由系列高斯分布混合而成。在给定实体时, 某个高斯分布分量占主要作用, 这个知识关系表现出对应的某个语义, 从而解决多重关系语义问题。形式化定义如下:

$$\mathbf{t} - \mathbf{h} | \mathbf{r} \sim \sum_{m=1}^M \text{coe}_{r,m} N(\mathbf{u}_{r,m}, \sigma_{r,m}), \quad (42)$$

$$P\{\text{tri}\} = \sum_{m=1}^N \text{coe}_{r,m} \times \exp\{-\|\mathbf{h} + \mathbf{u}_{r,m} - \mathbf{t}\|_{L_2}\}$$

符号 $N, \mathbf{u}_{r,m}, \text{coe}_{r,m}$ 分别表示一个关系的高斯分布分

量数，高斯分布分量的均值，高斯混合系数。基于具体知识库训练 TransG 模型，模型可以捕获关系在不同实体场景下的多语义。

2.3 复空间的平移模型

RotatE 算法：

RotatE 模型^[40]将三元组投影到复数向量空间，并将关系嵌入定义为旋转矢量，令三元组的映射操作等价于实体嵌入沿坐标轴旋转的过程，具体地，作者定义如下评分函数模型将每个关系定义为在复向量空间中从源实体到目标实体的旋转。将实体和关系映射到复向量空间，并将每个关系定义为从源实体到目标实体的旋转：

$$E(\text{tri}) = \| \mathbf{h} \circ \mathbf{r} - \mathbf{t} \|_{L_1/L_2} \quad (43)$$

式中，圆圈符号表示 Hadamard 乘积。

3 算法模型总结

3.1 算法的建模能力

知识表示算法旨在把知识映射到向量空间，使得数值运算变得可操作和有意义。算法的建模能力很大程度上取决于对 KG 中关系模式和关系映射属性的建模能力。知识图谱中重要的关系模式有：对称关系、非对称关系、互逆关系、组合关系，重要的关系的映射属性有：一对一关系、一对多关系、多对一关系和多对多关系。表 1 是代表性的算法在建模能力方面的对比，可以看出 RotatE 算法、HousE 算法和 SpaceE 算法覆盖了 4 种关系模型和映射属性，其它算法只能建模部分的关系模式。

表 1 典型算法的建模能力对比算法

| 算法名称 | 关系模式 | | | | 关系映射属性 |
|---------|------|-----|-----|-----|--------|
| | 对称 | 反对称 | 互逆 | 组合 | |
| TransE | 不支持 | 支持 | 支持 | 支持 | 不支持 |
| TransH | 支持 | 支持 | 不支持 | 不支持 | 支持 |
| TransR | 支持 | 支持 | 不支持 | 不支持 | 支持 |
| CTransR | 支持 | 支持 | 不支持 | 不支持 | 支持 |
| TransD | 支持 | 支持 | 不支持 | 不支持 | 支持 |
| RotatE | 支持 | 支持 | 支持 | 支持 | 支持 |
| TransET | 支持 | 支持 | 不支持 | 不支持 | 支持 |
| TKRL | 支持 | 支持 | 不支持 | 不支持 | 支持 |
| IKRL | 不支持 | 支持 | 支持 | 支持 | 不支持 |
| HousE | 支持 | 支持 | 支持 | 支持 | 支持 |
| SpaceE | 支持 | 支持 | 支持 | 支持 | 支持 |

3.2 算法的综合分析

以问题背景、算法模型原理的思路，详细阐述了典型平移模型算法，说明了各算法模型间的演化关系。表 2 和表 3 是结合已有的研究成果对其进行总结梳理，重点从算法研究背景、解决的问题思路、与其它算法演化关系等方面对比总结。

表 2 平移模型算法优缺点对比总结

| 算法名称 | 优点 | 缺点 |
|---------|--------------------------------|-----------------------------|
| TransE | 思路简单清晰，计算量相对小 | 无法对关系多重属性进行建模 |
| TransH | 具备建模关系多重属性能力 | 实体和关系建模在同空间 |
| TransC | 对 3 种（概念实例/概念层级/普通）三元组分别建模 | 无法对关系多重属性进行建模 |
| TransR | 考虑了关系和实体多样性 | 矩阵计算复杂，头尾实体投影矩阵一样，且矩阵只由关系决定 |
| TransD | 计算较简单，参数少，投影过程同时受实体/关系决定 | 没有考虑关系的异质性和非均衡性 |
| TransG | 首次提出生成式模型，基于的基于概率空间，支持关系多重语义建模 | 对于一个关系的多重语义无法确定具体重数 |
| PTransE | 融入了关系的路径信息 | 参考 TransE 算法 |
| TKRL | 利用实体类型生成投影矩阵 | 参考 TransR 算法 |
| IKRL | 融入了实体图像信息 | 参考 TransE 算法 |
| TransET | 利用实体类型生成投影矩阵 | 计算复杂，花销比 TransE/H/R 大 |

3.3 算法的性能

综合已有研究实验性能数据，以知识图谱的实体链接预测任务测试算法模型，从定量角度对模型进行对比总结。评价指标是知识图谱链接预测任务的平均排名：Mean Rank 和 TOP10 命中率，在性能表中分别使用“MR”、“H@10”标记。平均排名，把三元组某个位置的实体轮流替换成词表中的其他实体，构建三元组负例，利用算法模型计算三元组的评分值（正样本的值小，负样本的值大）。对评分值按升序排序，正样本在排序表中的平均位置就是平均排名。TOP10 命中率定义为正样本在 TOP10 的数量比例。另外，被构建的负例有可能是存在于知识图谱中的正例，这不应当被视作负例。因此，在对候选进行排名之前，先将这些三元组过滤掉，然后评测，这种评测方法称为“过滤”。将初始的评测方法称为“原始”。以数据集 WIN18、数据集 FB15K 为验证数据，前者以包括概念知识为主，后者主要包括实例知识为主。由于两个数据集不太适合 TransC 模型，因此在 YAGO39 数据集^[27]计算 TransC 模型的性能指标。此外，KR-EAR 模型的指标基于 FB24K 数据集^[41]计算。

指标梳理如表 4~6 所示。从指标数据表中可知，一些考虑到更复杂情况的模型，其指标数据更优。同时也出现一个现象，算法在某指标项表现好，但是在另外指标项未必占有优势，可能的原因就是知识图谱的表达是一个复杂的问题，平移模型基本上代表了算法的性能

表 3 平移模型算法对比总结

| 算法名称 | 演化关系 | 聚集的问题 | 算法模型思路 |
|---------|-------------|------------------|---|
| TransE | 开创者 | 知识的向量表示 | 实体与关系定义为同空间向量,使用向量的相似性度量三元组成立置信度 |
| TransH | 改进 TransE | 关系多重属性的建模 | 先将实体向量投影到关系的超平面,然后使用投影向量的相似性度量三元组成立置信度 |
| TransC | 改进 TransE | 概念实体与普通实体分别建模 | 将概念编码成球体,实例编码为向量。对于实例化关系,用向量与球体关系判定;对于子类关系,使用球体间包含关系判定;对于其它的三元组,按照 TransE 模型的算法进行处理 |
| TransR | 改进 TransE | 实体和关系具有区别的语义 | 为每种关系设计映射矩阵,然后再把实体向量从实体空间映射到关系空间 |
| CTransR | 改进 TransR | 同关系在不同实体对中具有区别语义 | 对关系先聚类,再从聚类中选择类的映射矩阵,然后再把实体向量从实体空间映射到关系空间 |
| TransD | 改进 TransR | 投影过程应受到实体和关系共同影响 | 每个实体和关系由投影、语义两个向量来表示。使用关系、实体的投影向量构造映射矩阵 |
| TransA | 改进 TransE | 向量各维度具有不同的重要性 | 模型把欧式距离修改成马氏距离,实现为每一维的学习设置不同权重,满足自适应转换 |
| TransG | 改进 KG2E | 知识图谱的关系多重语义的建模问题 | 采用高斯混合模型描述关系,根据实体对确定占主导作用的高斯分布分量,从而表达对应的语义 |
| PTransE | 改进 TransE | 知识关系路径信息的利用 | 把头尾实体间路径信息融入到 TransE 平移模型 |
| TKRL | 改进 TransR | 知识实体类型信息的利用 | 投影矩阵的构建以实体层次类型信息基础,再将实体投影到关系空间,然后应用平移模型 |
| IKRL | 改进 TransE | 知识图像信息的利用 | 将实体图像的卷积特征融入到平移模型,实现对图像特征空间与知识空间融合,再运用平移模型 |
| TransET | 改进 TransE | 知识实体类型信息的利用 | 引入循环卷积操作,基于类型和实体生成投影矩阵,然后应用平移模型 |
| TransS | 改进 TransE | 同实体对的多语义关系 | 关系由单一向量替换成包括头实体、尾实体、关系信息等信息的组合向量,然后再应用平移模型 |
| SpaceE | RotatE 的扩展版 | 知识图谱的关系多重语义的建模问题 | 运用线性变换建模三元组的关系,头实体经线性变换后再度量其与头实体相似度,再评估三元组 |

表 4 实体链接预测性能对比表 (raw 评估数据)

| 算法名称 | WIN18 数据集 | | FB15K 数据集 | |
|-------------------------|-----------|------|---------------------|----------------------|
| | MR | H@10 | MR | H@10 |
| TransE ^[22] | 263 | 75.4 | 243 | 34.9 |
| TransH ^[26] | 318 | 75.4 | 211 | 42.5 |
| TransR ^[33] | 232 | 78.3 | 226 | 43.8 |
| CTransR ^[33] | 243 | 78.9 | 233 | 44.0 |
| TransD ^[35] | 242 | 79.2 | 211 | 49.4 |
| TransG ^[39] | 377 | 82.5 | 152 | 55.9 |
| PTransE ^[32] | — | — | 207 ^[25] | 51.4 ^[25] |
| TKRL ^[34] | — | — | 184 | 49.2 |
| TransET ^[29] | — | — | 62 | 76.4 |
| HousE ^[37] | 137 | 96.4 | 38 | 89.8 |
| SpaceE ^[36] | — | 88.3 | — | 95.9 |

表 5 实体链接预测性能对比表 (FB24K 数据集^[41], raw 评估数据)

| 算法名称 | 头实体预测 | | 尾实体预测 | |
|------------------------|-------|------|-------|------|
| | MR | H@10 | MR | H@10 |
| TransE ^[22] | 385 | 20.2 | 134 | 51.4 |
| TransH ^[26] | 416 | 17.7 | 147 | 50.0 |
| TransR ^[33] | 394 | 20.5 | 125 | 53.4 |

表 6 实体链接预测性能对比表 (YAGO39 数据集^[27], raw 评估数据)

| 算法名称 | MR | H@3 | H@10 |
|------------------------|-------|------|------|
| TransH ^[26] | 0.102 | 24.0 | 45.1 |
| TransR ^[33] | 0.112 | 33.8 | 56.7 |
| TransD ^[35] | 0.113 | 19.0 | 35.4 |
| TransC ^[27] | 0.087 | 50.0 | 69.2 |

水平,一些改进只是局部优化,尚未有形成绝对优势的算法方案,存在很大的改进空间。

4 研究展望

知识图谱表示学习是一个非常具有挑战性的领域,对于未来工作的展望如下。

1) 表示空间类型:

知识图谱转换到哪类型数据空间才是理想表示,这是知识表示学习需要关注的问题。综述分析平移模型,学者们探索了欧式空间、马氏空间、高斯分布空间、复数空间、四元组空间等类型。在基于卷积神经网络或图神经网络的算法中,知识图谱被转换到更为复杂、更难解释的空间类型。在空间类型数量的选择上,TransS、

TransH、TransC 等算法模型使用同一种数据空间类型，TransR、TransD、TKRL 等算法模型却采用多种数据空间类型。由于知识图谱的复杂性，关系的重数属性，关系性质多样，有的表现出递归、传递、对称性质，有的则没有。科学合理选择数据空间类型及其数量，将会直接影响后续知识图谱任务的机器计算和推理。

2) 编码模型：

编码模型本质上是解决把实体和关系的符号转换到数据空间类型的问题，即是把知识图谱转换到选择的其它数据空间映射过程。有两个关键点：1) 编码能力，要求模型尽可能把知识图谱的内涵全部编入，综合分析平移模型的发展演化过程，大部分模型就是沿着扩展编码能力的路径思路改进；2) 编码效率，显然在知识海量的时代，面对的都是大规模的知识图谱，编码效率关乎模型在工程应用上的可行性。

3) 多模态知识图谱研究：

知识图谱三元组的语义较为精炼和抽象，作为知识图谱的内部信息，被知识图谱嵌入模型很好地组织起来，然而这些模型在链接预测、实体对齐等实际应用中的性能还远远不够，没有足够的建模能力应对复杂关系类型。已有的一些模型尝试结合实体类型、关系路径、属性信息、实体描述、图像信息，均取得更好的性能。利用好外部信息对知识图谱的表示性能的提升意义重大。将来，既可以在外部信息类型着力挖掘，探索挖掘例如规则约束信息、关系路径等更高阶信息和音频、视频等更复杂媒体为知识表示服务，又可以在多模态知识方面拓展研究，探索在知识图谱中结合多种不同模态数据，对实体和关系进行表示学习的技术。

4) 时序知识图谱表示：

随着信息社会的高速发展，知识更新变得越来越快，某些应用场景下的知识图谱，随着时间的推移，实体和关系发生剧烈变化。让算法模型周期性的重新运行，更新知识的表达内容的策略不可取。理应把时间维度纳入考虑，设计适应时序动态分析的技术模型，对动态时序知识图谱的表示学习，表示向量及时与知识图谱的变化同步准确表达知识。当下时序知识图谱的研究已引起研究者关注，但是尚未看到成熟的成果。未来研究可以着眼于针对时间戳的表示，来实现面向事实的时间预测。

5 结束语

知识图谱的表示是知识图谱智能的基石，虽然已经研究出很多的表示模型成果，且取得不错的性能，但是在泛化能力方面仍然有大的改进空间。本文综合分析了知识图谱的表示技术，并重点对平移模型的算法体系详

细梳理，在综述知识图谱的表示学习研究过程，总结展望该领域重要的研究重点和发展方向。文章能为知识图谱表示学习领域的研究者提供学习参考，能启发学者的研究思路。

参考文献：

- [1] WANG Q, MAO Z, 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.
- [2] DAI Y, WANG S, XIONG N, et al. A survey on knowledge graph embedding: approaches, applications and benchmarks [J]. Electronics, 2020, 9 (5). DOI: <https://doi.org/10.3390/electronics9050750>.
- [3] CHOUDHARY S, LUTHRA T, MITTAL A, et al. A survey of knowledge graph embedding and their applications [J]. Eprint: ArXiv, 2021. DOI: 10.48550/arXiv.2107.07842.
- [4] GESESE G A, BISWAS R, SACK H A. Comprehensive survey of knowledge graph embeddings with literals: techniques and applications [C] // Proceedings of the Workshop on Deep Learning for Knowledge Graphs, 2019: 31 - 40.
- [5] 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, 2014: 601 - 610.
- [6] CUI W, XIAO Y, WANG H, et al. KBQA: learning question answering over qa corpora and knowledge bases [C] // Proceedings of the VLDB Endowment, 2017, 10: 565 - 576.
- [7] HAO Y, ZHANG Y, LIU K, et al. An end-to-end model for question answering over knowledge base with cross-attention combining global knowledge [C] // Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics, 2017: 11 - 22.
- [8] YANG B, MITCHELL T. Leveraging knowledge bases in LSTMS for improving machine reading [C] // Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics, 2017: 1436 - 1446.
- [9] WANG J, WANG Z, ZHANG D, et al. Combining knowledge with deep convolutional neural networks for short text classification [C] // Twenty-Sixth International Joint Conference on Artificial Intelligence, 2017: 2915 - 2921.
- [10] KAMINSKI M, GRAU B C, KOSTYLEV E, et al. Foundations of declarative data analysis using limit datalog programs [C] // Twenty-Sixth International Joint Conference on Artificial Intelligence, 2017: 1123 - 1130.

- [11] BELLOMARINI L, GOTTLÖB G, PIERIS A, et al. Swift logic for big data and knowledge graphs [C] // Twenty-Sixth International Joint Conference on Artificial Intelligence, 2017: 2 - 10.
- [12] CHEN J, LECUE F, PAN J, et al. Knowledge-based transfer learning explanation [C] // International Conference on Principles of Knowledge Representation and Reasoning, 2018: 349 - 358.
- [13] WANG X, YE Y, GUPTA A. Zero-shot recognition via semantic embeddings and knowledge graphs [C] // Computer Vision Pattern Recognition, 2018: 6857 - 6866.
- [14] ZHANG F Z, YUAN N J, LIAN D F, et al. Collaborative knowledge base embedding for recommender systems [C] // Proc. of the 22nd ACM SIGKDD Int' l Conf. on Knowledge Discovery and Data Mining, San Francisco, 2016: 353 - 362.
- [15] NICKEL M, TRESP V, KRIEGEL HP. Factorizing YAGO: Scalable machine learning for linked data [C] // Proceedings of the 21st international conference on World Wide Web, 2012: 271 - 280.
- [16] LIU HX, WU YX, YANG YM. Analogical inference for multi-relational embeddings [C] // Proceeding of the 34th International Conference on Machine Learning, Sydney, 2017: 2168 - 2178.
- [17] DETTMERS T, MINERVINI P, STENETORP P, et al. Convolutional 2D knowledge graph embeddings [C] // Proceeding of the 32th AAAI Conference on Artificial Intelligence, Louisiana, 2018: 1811 - 1818.
- [18] 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] // Proceeding of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, New Orleans, 2018: 327 - 333.
- [19] JIANG X T, WANG Q, WANG B. Adaptive convolution for multi-relational learning [C] // Proceeding of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2019: 978 - 987.
- [20] NGUYEN D Q, VU T, NGUYEN T D, et al. A capsule network-based embedding model for knowledge graph completion and search personalization [C] // Proceeding of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2019: 2180 - 2189.
- [21] VASHISHTH S, SANYAL S, NITIN V, et al. Composition-based multi-relational graph convolutional networks [C] // Proceedings of the 8th International Conference on Learning Representations, 2020: 5250 - 5265.
- [22] 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 Information Processing Systems, 2013, 2: 2787 - 2795.
- [23] GOYAL P, FERRARA E. Graph embedding techniques, applications, and performance: a survey [J]. Knowledge-Based Systems, 2017, 151 (1): 78 - 94.
- [24] CAI H, ZHENG V W, CHANG K C C. A comprehensive survey of graph embedding: problems, techniques, and applications [J]. IEEE Transactions on Knowledge and Data Engineering, 2018, 30 (9): 1616 - 1637.
- [25] LIN Y, HAN X, XIE R, et al. Knowledge representation learning: a quantitative review [J]. Eprint: ArXiv, 2018. DOI: arXiv:1812.10901.
- [26] 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, 28: 1112 - 1119.
- [27] LYU X, HOU LEI, LI J, et al. Differentiating concepts and instances for knowledge graph embedding [C] // Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing, 2018: 1971 - 1979.
- [28] ZHANG X, YANG Q, XU D. TranS: transition-based knowledge graph embedding with synthetic relation representation [J]. Findings of the Association for Computational Linguistics: EMNLP 2022, 2022: 1202 - 1208.
- [29] WANG P, ZHOU J, LIU Y, et al. TransET: knowledge graph embedding with entity types [J]. Electronics, 2021, 10 (12): 1 - 11.
- [30] XIE R, LIU Z, LUAN H, et al. Image-graph embedding: a survey of approaches and applications [C] // International Joint Conference on Artificial Intelligence, 2017: 3140 - 3146.
- [31] SHUTOVA E, KIELA D, MAILLARD J. Black holes and white rabbits: metaphor identification with visual features [C] // Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2016: 160 - 170.
- [32] LIN Y, LIU Z, LUAN H, et al. Modeling relation paths for representation learning of knowledge bases [C] // Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing, 2015: 705 - 714.

(下转第 29 页)