

# 面向人工智能深度学习的知识图谱 补全技术与应用综述

姜颖, 祁云嵩

(江苏科技大学 计算机学院, 江苏 镇江 212000)

**摘要:** 知识图谱旨在为各种领域提供更加全面可靠的服务, 在实际应用中的价值不可估量, 为了使其不断更新和趋于完整, 知识图谱补全技术开始被提出; 近几年, 随着人工智能和深度学习的兴起, 许多国内外学者对知识图谱补全方向进行深入研究, 出现了很多面向人工智能深度学习的知识图谱补全模型, 但相关的文献综述却并不多; 为了提供一个全面了解该领域的框架, 有助于读者能够掌握当前的研究进展和应用情况, 并为未来的研究和应用提供一些参考; 通过介绍其概念和典型的知识图谱, 从深度学习的知识补全技术的3个角度展开, 分析和归纳了目前基于深度学习的知识图谱补全模型, 探讨了不同模型的优缺点及改进模型; 同时, 讨论了现阶段知识图谱补全任务所存在的问题和挑战, 并探索了该领域的应用方向和发展前景; 综上所述, 深度学习在知识图谱补全中具有巨大的发掘价值, 亟待学者们进行更深入的研究和进一步地创新。

**关键词:** 深度学习; 知识图谱补全; 链接预测; 卷积神经网络; 图神经网络

## Overview of Knowledge Graph Completion Technology and Applications for Deep Learning in Artificial Intelligence

JIANG Ying, QI Yunsong

(School of Computer, Jiangsu University of Science and Technology, Zhenjiang 212000, China)

**Abstract:** Knowledge graph aims to provide more comprehensive and reliable services for various fields, its value is immeasurable in practical applications, in order to make it constantly updated and complete, knowledge graph completion technology begins to be proposed; In recent years, with the developments of artificial intelligence and deep learning, many scholars at home and abroad conduct in-depth research on the direction of knowledge graph completion, and proposes many knowledge graph completion models for artificial intelligence deep learning, but there are not many relevant literature reviews. In order to provide a comprehensive understanding framework of the field, it helps readers to grasp current research progress and application, which provides some references for future research and application; By introducing its concept and typical knowledge graph, a current knowledge graph completion model based on deep learning is analyzed and summarized from three perspectives of deep learning knowledge completion technology, and the advantages and disadvantages of different models and the improved model are discussed. At the same time, the problems and challenges of current knowledge graph completion tasks are discussed, and the application direction and development prospects of this field are explored. In summary, deep learning has a great exploration value in knowledge graph completion, which urgently requires scholars to implement more in-depth research and further innovation.

**Keywords:** deep learning; knowledge graph completion; link prediction; convolutional neural network; graph neural network

### 0 引言

大数据时代, 知识图谱作为一种语义网络<sup>[1]</sup>, 现已成为人工智能领域的动力之一。早期谷歌公司提出知识图谱<sup>[2]</sup>, 旨在提升搜索引擎的搜索效果。若将知识图谱看作现实世界信息的一种结构化数据时, 可以进行查询、统计、挖掘。若将知识图谱看作知识时, 可以进行语义理解、解

释和推理等。知识图谱以三元组形式描述了概念、实体及其关系, 可以有效地组织和表示知识, 是一项非常具有研究价值的技术。如在搜索引擎、人机交互、智能医疗<sup>[3]</sup>、舆情分析、智能教育、智能推荐系统<sup>[4]</sup>等各方面, 可以使知识在高级应用中得到更为有效地利用。

知识图谱是认知智能的核心技术之一, 随着技术的进步, 知识图谱技术的核心价值主要体现在灵活集成异构数

收稿日期: 2023-06-03; 修回日期: 2023-07-05。

基金项目: 国家自然科学基金(62261029)。

作者简介: 姜颖(1996-), 女, 硕士。

祁云嵩(1967-), 男, 博士, 教授。

引用格式: 姜颖, 祁云嵩. 面向人工智能深度学习的知识图谱补全技术与应用综述[J]. 计算机测量与控制, 2024, 32(5): 8-16.

据源、描述数据间的关联、实现实体链接、进行大规模知识推理等。近几年, 知识图谱领域研究围绕着时序知识图谱<sup>[5]</sup>、知识图谱应用<sup>[6]</sup>、知识图谱表示学习<sup>[7-8]</sup>、知识图谱获取<sup>[9]</sup>这 4 个大方向展开。

更细化来说, 知识图谱补全是属于知识图谱获取中的一个研究小方向, 也是能够发现新知识的重要手段。为了实现对知识图谱不断补充完善和及时更新, 解决许多大规模开放知识图谱仍然存在不完整和不准确的问题, 则需要依靠知识图谱补全技术。知识图谱补全可以不断向不完整的知识图谱中添加新的正确的知识, 也可以根据现有知识图谱中推断出三元组中缺失的部分, 又被称为头、尾实体或者关系的链接预测<sup>[10]</sup>。

近几年, 在机器学习、深度学习等技术的推动下, 知识图谱补全已经成为一个日益活跃的研究领域。越来越多的研究综述文献对知识图谱补全技术进行了分析性地介绍和全面性地总结, 以便可以更加全面深入地了解知识图谱补全的现状、发展趋势和未来研究方向。

其中, 文献 [11] 从静态知识图谱补全和动态知识图谱补全方面进行了综述, 文献 [12] 将知识图谱的补全任务分为传统的表示学习和图神经网络表示学习进行了综述, 文献 [13] 从图神经网络的角度对知识补全方法进行了综述。

但是, 尽管已有上述诸多有关知识图谱补全研究性综述文献, 目前却仍缺乏从基于深度学习的角度对现有的知识图谱补全模型研究进行系统、深入地梳理与归纳的工作。本文将全面地归纳总结面向深度学习的知识图谱补全模型最新研究进展, 并指出当前遇到的挑战以及具体应用场景, 最后做出小结。

## 1 国内外研究现状

目前, 国内外开发了大量的大规模知识图谱, 并为许多重要的人工智能任务提供了有效的基础。在国内, 主要的知识图谱项目包括: 由清华大学和中国科学院软件研究所等共同开发的 XLORE<sup>[14]</sup>; 由中国科学院自动化所开发的 OpenKG<sup>[15]</sup>; 由复旦大学知识工场实验室所开发的 CN-Dbpedia<sup>[16]</sup>等。在国外, 早期有由普林斯顿大学计算机科学家 George A. Miller 创建的 WordNet<sup>[17]</sup>; 有维基媒体基金会的 Wikidata<sup>[18]</sup>; 有 Metaweb 公司的 Freebase<sup>[19]</sup>; 有谷歌公司的 Knowledge Vault<sup>[20]</sup>; 有卡耐基梅隆大学的 NeLL KB<sup>[21]</sup>等, 如表 1 所示。

在早期, 很多典型的神经网络模型出现并被用于知识补全任务。NTN 模型<sup>[22]</sup>是一种利用张量表示实体和关系之间的交互, 并通过神经网络进行预测的方法。其主要思想就是采用双线性张量代替神经网络中的线性变换层。在得分函数中同时使用双线性 and 线性操作, 如公式 (1) 所示。此外, 当该模型去除双线性操作的部分就是 SLM<sup>[22]</sup>, 其属于一种最简单的单层线性模型, 如公式 (2) 所示。评分函数分别如下:

表 1 国内外典型的大规模知识图谱比较

知识图谱	国内外	实体数量	跨语言	主要特点
XLORE	国内	63 M	是	具有丰富的语义关系, 开放数据, 拥有多种查询接口
OpenKG		—	是	支持多源数据、定期进行数据同步与更新、开源共享
CN-Dbpedia		17 M	是	针对单数据源中文百科类网站操作, 质量高更新快
NeLL KB	国外	2 M	否	采用互联网挖掘的方法自动抽取三元组知识
WordNet		0.15 M	否	结构灵活, 可以查找单词的同义词和反义词
Wikidata		49 M	是	支持自由协作编辑, 支持多语言, 其内容都是结构化的信息
Freebase		250 M	是	开放共享的、协同构建。不对顶层本体做非常严格的控制

$$f(h, r, t) = r^T \tanh(h^T M_r t + M_r^h h + M_r^t t + b_r) \quad (1)$$

$$f(h, r, t) = r^T \tanh(M_r^h h + M_r^t t) \quad (2)$$

其中:  $h^T M_r t$  为双线性操作的部分,  $M_r^h h + M_r^t t$  为线性操作的部分。

Bordes 等人在 2014 年提出了 SME 模型<sup>[23]</sup>, 该模型采用神经网络架构进行语义匹配, 将实体和关系的低维嵌入向量作为 SME 模型的输入, 使用矩阵运算来获取实体之间的语义交互。

MLP<sup>[24]</sup>模型采用多层感知机推理三元组, 多层感知机的输入为实体和关系的低维嵌入向量, 通过得分函数得到三元组的得分。MLP 模型属于 NTN 模型的简化, 通过一个标准的多层感知器代替了 NTN 模型的交互部分。

NAM<sup>[25]</sup>模型通过建立深度神经网络实现语义匹配, 在其深层神经网络中具有多层非线性激活, 可以自动学习实体和关系之间的语义表示, 并根据这些表示来预测缺失的实体或关系, 可以应用于三重分类等概率推理任务。

如表 2 所示, 对以上 5 种有关早期神经网络的知识补全模型的评分函数和复杂度进行归纳。

表 2 神经网络模型总结

模型	复杂度		评分函数
	时间	空间	
NTN	$o(d^2 k)$	$o(nd + md^2 k)$	$r^T \tanh(h^T \tilde{M}_r t + M_r^h h + M_r^t t + b_r)$
SLM	$o(dk)$	$o(nd + mdk)$	$r^T \tanh(M_r^h h + M_r^t t)$
SME	$o(d^2)/o(d^3)$	$o(nd + md)$	$(M_r^h h + M_r^t r + b_r)^T (M_r^t t + M_r^r r + b_r) + ((M_r^h h)^o (M_r^r r + b_r))^T ((M_r^t t)^o (M_r^r r + b_r))$
MLP	$o(d^2)$	$o(nd + md)$	$w^T \tanh(M^1 h + M^2 r + M^3 t)$
NAM	$o(Ld^2)$	$o(nd + md)$	$f_r(h, t) = t^T z^{(L)}$ $z^{(0)} = \text{ReLU}(a^{(0)}), a^{(0)} = M^{(0)} z^{(l-1)} + b^{(0)}$ $z^{(0)} = [h; r]$

在深度学习的方面，将已有的基于深度学习的知识图谱补全相关研究主要分成 3 个方面进行展开，分别是：基于卷积神经网络的知识图谱补全模型、基于图神经网络的知识图谱补全技术模型、基于 Transformer 神经网络的知识图谱补全模型。

## 2 基于卷积神经网络的知识图谱补全模型

最开始，卷积神经网络主要用于图像处理相关的任务，因其对多尺度的局部空间特征的提取和融合并形成一种高效表示的特点，故而在后期，卷积神经网络逐渐被用于知识补全方向，并得到了迅速发展。通过按照维度的不同进行简述对比，然后介绍其改进模型的相关特点。

### 2.1 不同维度的卷积模型

ConvKB<sup>[26]</sup>模型利用一维卷积进行链路预测，可以对知识图谱中的实体与关系之间的特征进行捕获。ConvKB 首先将一个三元组变成一个三列矩阵，将其作为卷积层的输入，映射到不同的特征空间。然后将其连接起来创建单一的特征向量。通过特征向量和权重向量的点积计算其可信度得分。

ConvE<sup>[27]</sup>模型利用二维卷积层进行链路预测，其主要由单层卷积网络、处理嵌入维度的投影层和内积层组成。通过对头实体和关系的表示进行重组和连接，再将得到的矩阵作为卷积输入。经过卷积处理，获得相应的特征映射矩阵，将得到的特征映射矩阵投影到  $k$  维空间中进行矢量化，并与所有实体的矢量表示进行匹配。其中，dropout 操作在该模型中被大量使用，来避免过拟合。

Conv3D<sup>[28]</sup>模型采用三维卷积层用于知识图谱中的链接预测，深层次地挖掘实体与关系之间的交互。首先分别对头、尾实体和关系的表示进行重构和堆叠，将得到的矩阵输入到卷积层得到特征映射矩阵，并采用了 ConvE 模型中同样的 dropout 操作。然后将这些特征映射连接为一个向量，最终通过投影层计算出三元组的打分结果。

以上 3 种利用不同维度的卷积神经网络补全模型对比如图 1 所示。其中，与一维卷积相比，二维卷积能够捕获出更多的特征交互，即二维卷积增强了模型的表现力。一维卷积是将一维的嵌入进行拼接，从而捕捉到两个向量拼接点处的一些交互<sup>[27]</sup>。二维卷积是将二维嵌入堆叠起来，从而能够捕捉到整个拼接行的交互。与一维和二维卷积相比，三维卷积模型在保持三元组的平移特性的情况下，能够更好地深层次挖掘特征间的相互作用。

### 2.2 改进模型

ConvR<sup>[29]</sup>模型是对 ConvE 中存在的两种问题的一种改进。其一，ConvE 模型无法对实体和关系之间的交互进行全面地捕获；其二，ConvE 模型只能在实体和关系的矩阵相邻的区域中去进行建模交互。如图 2 所示，该模型以关系的嵌入向量为卷积核，对实体的嵌入向量做二维卷积操作，以降低参数量，确保关系与实体间的交互可达到最大。

与基础模型相比，基础模型中使用的是全局过滤器，而 ConvR 使用的是关系嵌入向量构建出来的自适应过滤器。

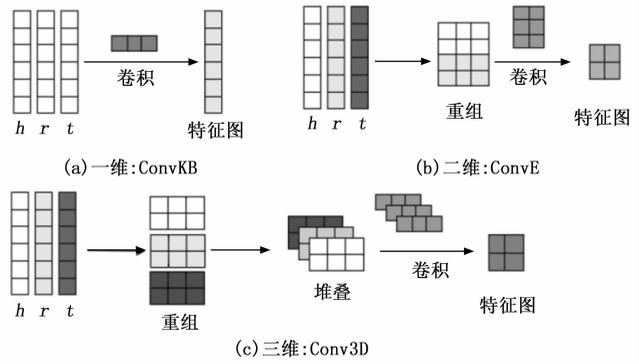


图 1 3 种卷积神经网络补全模型

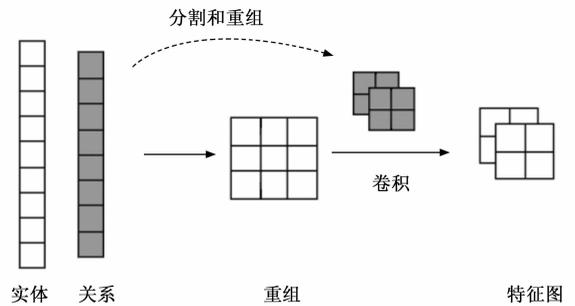


图 2 ConvR 模型

CapsE<sup>[30]</sup>是在 ConvKB 模型基础上的一个扩展，也是首次提出了利用胶囊网络进行知识图谱补全。对头实体、关系和尾实体嵌入向量组成的一个三列矩阵进行卷积操作，生成不同的特征映射来构造低级胶囊，经过路由过程得到一个连续的向量。最后根据连续向量的长度对三元组得分情况进行判断。

胶囊神经网络本质上是针对卷积神经网络中最大池化层的一种改进，最大池化层存在减少知识图谱中实体和关系向量的特征问题。CapsE 模型利用路由过程代替池化层，能够对知识图谱中实体和关系的全部特征信息进行有效保留，降低特征学习中的信息损失。如图 3 所示。

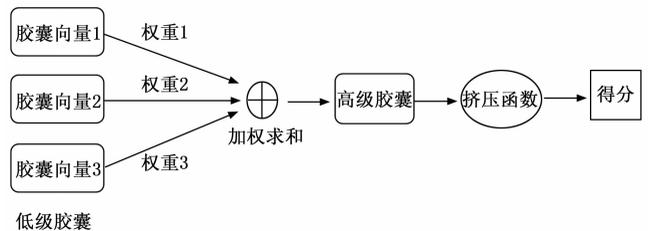


图 3 具体路由过程

定义  $u_i$  为第  $i$  个胶囊，其中  $i \in \{1, 2, 3, \dots, K\}$ ，每一个胶囊内神经元数量等于卷积核的数量， $c_i$  为耦合系数，即低级胶囊连接到下一层胶囊的概率值， $v$  为输出向量。在动态路由处理中，将从不同卷积核中获得的相同维度特征值封装为一个胶囊  $u_i$ 。其中，将其胶囊向量和权重矩阵相乘并求和生成高级胶囊  $e$ ，经过压缩函数  $\text{squash}()$

将向量长度压缩到 0 到 1 的范围之内。公式如下:

$$e = \sum_i c_i u_c(i) \quad (3)$$

$$\text{squash}(e) = \frac{\|e\|^2}{1 + \|e\|^2} \cdot \frac{e}{\|e\|} \quad (4)$$

$$v = \text{squash}(e) \quad (5)$$

InteractE<sup>[31]</sup> 是对 ConvE 模型做出的一种改进模型, 该模型旨在解决 ConvE 在捕捉交互方面能力欠缺的问题。通过采用校验重组和循环卷积代替 ConvE 中的简单特征重组, 以更深层的方式获取更多的特征交互作用。InteractE 模型中主要有特征置换和重组操作以及循环卷积三点创新。其中, 该模型提出了 3 种重组方式: stack、alternate 和 chequer, 如图 4 所示。stack 方式是将两个嵌入分为两行, 然后堆叠起来。alternate 方式是堆叠  $n$  行, 然后进行循环交替, 图中为  $n=1$  的实例。chequer 方式是每个元素交叉排列。

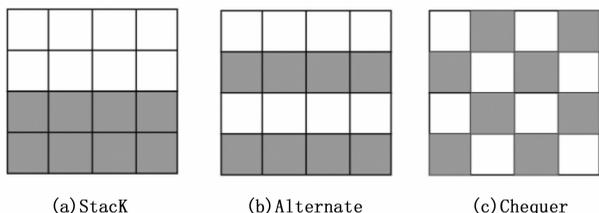


图 4 InteractE 的 3 种重组方式

### 3 基于图神经网络的知识图谱补全

随着深度学习研究范围的不断深入, Franco Scarselli 和 Marco Gori 等人最早提出了图神经网络的概念<sup>[32]</sup>。图神经网络突破了卷积神经网络的局限性, 卷积神经网络只能应用于欧几里得数据上, 而图神经网络可以突破卷积神经网络的局限, 通过聚合图结构的数据来获取信息, 故图神经网络更加适合处理知识图谱中的节点和边之间复杂的交互关系。图神经网络通过充分利用相邻实体和对应关系的信息<sup>[33]</sup>来学习到更完整的实体表示, 从而更精确地预测实体之间的链接关系。

图神经网络在知识补全方面有五大特点, 如图 5 所示。

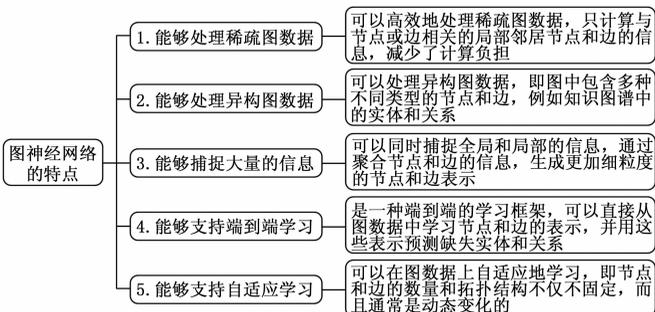


图 5 图神经网络的特点

#### 3.1 图卷积网络 GCN

图卷积网络是一种卷积神经网络图结构数据上的推广,

Bruna<sup>[34]</sup> 等人在 2013 年提出了关于图卷积网络的第一项重要研究。根据卷积方式的不同, 被分为基于谱域和基于空域两种不同的图卷积方法, 图卷积网络<sup>[35]</sup>是将图中的数据通过映射函数来聚合自身和邻域的特征信息。

R-GCN<sup>[36]</sup> 该模型首次提出用图卷积做知识图谱嵌入, 将图卷积网络从局部图邻域扩展到大规模关系数据。利用 R-GCN 进行编码, 获得嵌入向量, 然后解码器选择 DistMult 模型<sup>[37]</sup>, 进行边缘得分的计算。如图 6 所示。

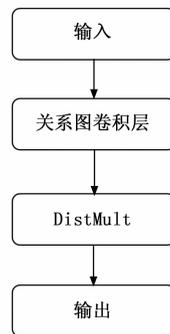


图 6 R-GCN 模型

针对 R-GCN 模型在编译器和译码器两端重复地引入相关参数而产生参数量增多的问题, TransGCN<sup>[38]</sup> 被提出。该模型一共有 TransE-GCN 和 RotatE-GCN 两种模型。在不同的模型中使用不同的方法, 将中心节点的异构邻域转换为同构邻域。将具有关联关系的相邻节点聚合成消息, 传播到中心节点, 有助于实体嵌入学习以及关系嵌入学习, 最后, 利用解码器获得预测结果。

R-GCN 模型仅仅对实体嵌入进行学习, 而 TransGCN 模型可以实现对实体嵌入和关系嵌入编码。但在 TransGCN 中, 学习过程中的关系嵌入忽视了实体的表征。

SACN 模型<sup>[39]</sup> 采用加权的图卷积网络解决图结构信息没有考虑在内的问题, 保留了翻译特性。该模型的编码器采用一个加权图卷积网络, 使用多个加权图卷积层的堆栈来从图结构和图节点的属性中学习信息。在 ConvE 的基础上对解码器 Conv-TransE 进行了一些改进, 并且取消了重组过程。首先使用多个卷积核进行卷积获得特征向量, 再拼接成一个向量与实体嵌入矩阵相乘, 得到评分情况。SACN 模型有效地结合了 ConvE 和图卷积网络的优点, 如图 7 所示。

CompGCN<sup>[40]</sup> 模型可以对一个多关系图中的节点嵌入和关系表示进行联合学习, 还对之前图神经网络方面存在的参数过载的一些问题进行了解决。CompGCN 模型中采用的是 R-GCN 提出的编码-解码框架, 在编码阶段, 将实体嵌入向量和关系嵌入向量组合起来, 再选择 TransE 或者 ConvE 等方式来对三元组进行解码。该模型在编码阶段就引入了关系嵌入向量, 在编码和解码时是同一套关系嵌入向量, 使得表征学习更加精准。为了保证 CompGCN 随着关系数量的增加而扩展, CompGCN 跨层共享关系嵌入。与

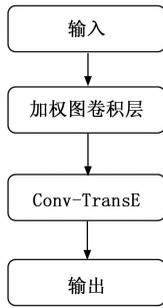


图 7 SACN 模型

R-GCN 为每个图卷积层定义一组基矩阵不同, CompGCN 只为第一个图卷积层定义基向量, 而后面的图卷积层通过可学习变换矩阵执行的关系嵌入变换来共享关系。这使得 CompGCN 比 R-GCN 具有更高的参数效率。

KE-GCN<sup>[41]</sup>是对 CompGCN 模型做的一个改进, 也是一种异构学习模型, 主要集中在节点和边缘知识的联合传播和更新、嵌入。传统的图卷积模型一般不关注学习边的嵌入, 且无法处理异构的边信息。KE-GCN 在计算关系嵌入时考虑关联的实体信息, 可以充分利用异构的节点信息和边信息, 并对两者的嵌入同时进行学习。

因其可以有效地建模图结构, 图卷积网络在知识图谱补全中越来越流行。基于图卷积网络的知识图谱补全模型通常使用编码器-解码器形式, 其中图卷积网络和知识图谱嵌入模型分别用作编码器和解码器<sup>[42]</sup>, 如图 8 所示。具体而言, 图卷积网络基于其相邻实体和关系生成实体和关系的表示, 知识图谱嵌入模型使用图卷积网络生成的表示对实体和关系之间的交互进行建模, 并且知识图谱补全中的图卷积网络会考虑到知识图谱中边的信息。

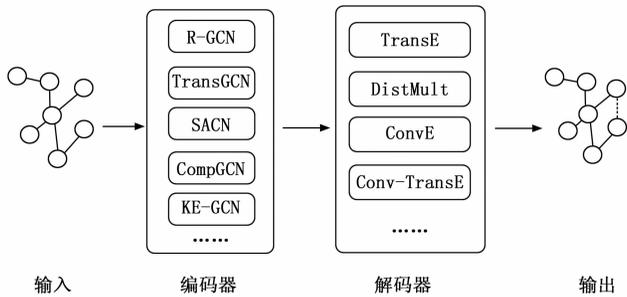


图 8 编码器-解码器示意图

### 3.2 图注意力网络 GAT

在图卷积网络的基础上, 图注意力网络<sup>[43]</sup>引入了注意力机制, 通过连接多个注意力来稳定学习过程并提高学习性能, 将二者进行了结合。图注意力网络本质上仍属于基于空域的图卷积方法, 拥有消息传递和特征更新两个关键特点。

图卷积网络是对图进行卷积运算的一种神经网络, 具有很强的学习能力。会在每个节点上进行卷积并对节点的代表形式进行更新。相比之下, 图注意力网络利用注意力

机制来加强节点间的信息传递。允许每个节点根据与其相邻节点的关系来动态地聚合相邻节点的信息。能够捕捉到更复杂的图结构, 可以控制不同节点之间的关注程度。简单来说, 图卷积网络中所有相邻节点的贡献是等价的, 而图注意力网络能够为相邻节点分配不同的重要程度, 本质上属于一个加权的图卷积网络。

KGAT<sup>[44]</sup>将图注意力网络应用到实体关系图和用户项目图的协同知识图谱上, 主要由嵌入层和注意力嵌入传播层以及预测层三部分组成。在嵌入层中, 通过保留知识图谱的结构, 对各结点进行了参数化。在注意力嵌入传播层, 通过递归的方法对相邻节点的嵌入信息进行传递, 同时利用注意力机制来学习每个相邻节点的权重, 最后在预测层进行预测结果的输出。

KGAT 模型的信息传递方法与图卷积网络以及 GraphSage 不同。KGAT 不但可以利用图的邻近结构, 而且可以表示出每个近邻在图中的重要程度。

在 KBGAT 模型<sup>[45]</sup>的研究中, 认为之前的基于卷积网络的模型几乎是对每个三元组采取单独处理的方式, 而忽略了在知识图谱邻近实体的表示中所蕴含的丰富语义关系。为了解决这一问题, 在注意机制中结合关系和相邻节点特征, 引入一种新颖的嵌入, 如图 9 所示。在知识补全任务中, KBGAT 模型利用图注意力网络和 ConvKB 分别作为编码器和解码器。为相邻节点分配不同的权重, 经过层传播图注意力。针对多跳关系问题, 利用关系组合进行补充辅助边。

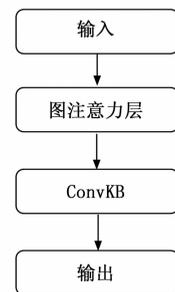


图 9 KBGAT 模型

LSA-GAT<sup>[46]</sup>提出了一种新的具有局部结构的邻域聚合策略来补全知识图谱。该模型考虑特殊的局部结构, 并推导出涵盖语义和结构信息的复杂表示。将 LSA-GAT、局部结构表示模块、特征融合模块和基于卷积神经的解码器相结合, 补全效果显著提高。但是, 聚合邻域实体不能有效地对关键关系建模, 并且忽视了实体和关系的不同方面。

RAGAT<sup>[47]</sup>通过将实体和实体关系映射到节点和边上, 然后使用图卷积网络来学习每个节点的嵌入表示。为解决使用多头注意力可能会出现大量的参数问题, 提出了 RAGAT 模型。RAGAT 结合了关系表示和注意力机制, 对原始知识图谱进行编码和建模, 从而提高了实体和关系之间的准确性。其中, 评分函数使用了 ConvE 和 InteractE 两种不同的解码器。

图注意力网络可以通过并行化实现顶点表示的高效计算,并且邻接权重矩阵可以应用于节点度数不同的应用场景。在知识图谱补全中,图卷积网络和图注意力网络都被用作编码器来编码实体和关系的语义信息。可以通过对不完整的三元组进行推理来补全缺失的关系。但是,在保持模型预测高准确性的前提下,图注意力网络比图卷积网络具有更好的拟合能力,并且能够处理更加复杂的知识图谱。因此,图注意力网络在知识图谱补全中通常表现更好。

#### 4 Transformer 网络的知识图谱补全

对于知识图谱中的实体和关系表示来说,是否充分利用了上下文信息显得十分重要,实践证明,引入 Transformer 神经网络后可以有效促进上下文本表示学习。在 Transformer 的模型加入了自注意力机制,可以有效地捕捉序列之间的长期依赖性,便于解决知识图谱中长距离的路径问题。

在 CokE<sup>[48]</sup>的研究中,认为以往的知识图谱嵌入方法都是学习静态的知识,即使是图卷积方法也只是在做静态嵌入的工作,没有真正学习到上下文知识。故提出了利用 Transformer 来编码知识图谱的动态嵌入。CoKE 模型的基本思路是通过 Transformer 网络模型来学习知识图谱中实体、关系的嵌入表示。具体来说,该模型一共使用了两个 Transformer 网络,一个用来编码实体,另一个用来编码对路径和上下文信息。CokE 还使用了一种基于 BERT 的上下文编码方式,以充分利用上下文信息。最终 CoKE 模型将两个编码器的输出连接起来,形成实体与路径嵌入的联合表示。该模型充分利用了知识图谱中的路径和上下文信息,从而提高了模型对实体和关系的理解能力。

BERT<sup>[49]</sup>是基于多层双向 Transformer 编码器上的最新一代的预训练上下文语言表示模型。采用掩码语言建模,以及下句预测预训练双向变压器编码器。能够在预训练的模型权重中捕捉到丰富的语言信息。在此基础上,许多知识补全模型尝试利用 BERT 或其变体来学习知识嵌入和预测事实。

KG-BERT<sup>[50]</sup>提出了一种语言模型预训练的思想,并且其实体和关系的编码器采用了双向编码器表示转换器模型。首先将三元组的实体和关系描述作为输入 BERT 框架的文本序列,自然地将知识图谱补全任务视为相应的序列分类任务。最后,KG-BERT 通过一个简单的分类层对序列化三元组的评分函数进行计算。

K-BERT<sup>[51]</sup>模型的主要功能是用来解决知识图谱领域的实体关系抽取和知识图谱补全这两个任务。K-BERT 以 BERT 为基础模型,充分挖掘知识图谱中的实体和关系信息。

具体来说,首先 K-BERT 将知识图谱中的实体和关系嵌入到基础模型的输入中,并为每个实体和关系赋予一个特定的标记,以便于模型进行区分。然后,模型通过联合学习实体关系抽取任务和知识图谱补全任务来提高模型性

能,并且采用多种技术来进行优化。K-BERT 模型的主要思想是通过协同学习来提高模型在知识图谱领域的性能,能够有效地提高模型对于知识图谱数据的理解和挖掘能力,为知识图谱补全和领域应用提供有力支持。

LP-BERT<sup>[52]</sup>模型包含多任务预训练和知识图谱微调两个训练阶段。预训练策略采用掩码语言模型、掩码实体模型和掩码关系模型,学习上下文语料库的知识,并通过预测基于语义的实体和关系元素从三元组中学习关系信息。在微调阶段,进行了三元组负采样以增加负采样比例,同时保持训练时间不变。相较于 KG-BERT 模型,LP-BERT 在训练任务的设计上增加了预测目标的精细化程度,并针对链接预测的微调更为巧妙和具有针对性。

基于 Transformer 神经网络的知识补全模型在高效性、精度、可扩展性和多语言支持等方面具有优势。由于可以利用大量的预训练数据,从而学习到更多的语言信息,并在知识补全任务中取得更好的效果。此外,还可以很容易地进行扩展,例如增加层数、增加隐藏单元数等,从而提高模型的性能。但是,由于基于自注意力机制进行建模,所以对于稀疏数据的处理较为困难,同时训练所需的时间和计算资源也较多。

#### 5 应用领域

目前大多数将知识图谱应用于搜索引擎优化、推荐系统和数据挖掘和分析等领域上。知识图谱一些具体的应用场景,如医疗、金融、网络客服、新闻等进行介绍。

##### 5.1 主要应用领域

###### 5.1.1 搜索引擎优化

在搜索引擎中,为了让用户能够得到最优的结果,往往需要从海量的数据中筛选出最相关的信息,并对其进行排序和推荐。搜索引擎是用户获取信息的主要方式之一,而知识图谱补全则可以提高搜索引擎答案的质量和相关性,增加搜索引擎的成功率,为用户提供更加准确和有用的搜索结果。

###### 5.1.2 推荐系统

随着互联网技术的发展,用户面临着海量在线内容的信息超载问题。推荐系统应运而生,其中协同过滤是一种传统的推荐方法<sup>[53]</sup>,根据用户的共同偏好和历史交互进行推荐。现有的基于知识图谱的推荐系统构建方法主要分为基于嵌入和基于路径的两种<sup>[54]</sup>。

基于嵌入的方法在推荐系统中表现出了很高的灵活性,但难以包含除文本之外的附加信息。基于路径的方法更自然和直观地对知识图谱进行了利用,但过于依赖于手工设计的元路径,在实际操作中很难对其进行优化。例如当某些实体和关系不属于一个领域的特殊场景时,将无法进行设计。

###### 5.1.3 数据挖掘和分析

在处理大规模数据时,往往难免会出现部分数据丢失或缺失的情况。通过运用知识补全技术,可以快速填补缺

失的数据,从而使得数据分析和挖掘效果更加准确和完整。数据挖掘和分析可以将实体和实体之间的关系组合为一个结构化的图谱,通过基于关系的算法进行分析,更好地展示实体之间的内在联系和属性特征。知识图谱可应用于很多的具体场景,这些应用可以帮助用户处理大量复杂数据,提供更全面、准确和有用的参考,为数据挖掘和分析带来更多的价值。

## 5.2 具体应用场景

### 5.2.1 医疗方面

为实现医疗人工智能,则需要建立医学知识图谱以满足医疗领域对知识的应用需求,医学知识图谱有术语多样化,精度高,关系丰富的特点。医学知识图谱旨在将开放的高质量的医学知识资源利用知识图谱的方式表示出来,通过获取基础的医学知识实现数据的标准化,促进医学知识更深度地应用。在文献 [55] 中通过技术实验和端到端应用实例,介绍了一种从电子病历构建医疗知识图谱的系统方法。

### 5.2.2 金融方面

智能金融目前主要关注于智能监管、信贷风险控制和智能反欺诈等领域。其中,知识图谱在反欺诈方面的应用越来越广泛,可以整合和分析海量数据和关系,帮助金融机构识别潜在的欺诈行为。在互联网环境下,虚假信息风险尤为突出,且许多欺诈信息隐藏于庞大复杂的关系网络中,知识图谱正是解决此类问题的有效工具。

智能风控利用阿里云的实时风险识别和决策引擎,并结合多年来的商业风控经验和机器学习算法,可以对垃圾账户、活动作弊、虚假信息等风险进行实时识别,有效地解决企业在营销和交易等方面可能出现的欺诈风险,从而减少企业的损失。在文献 [56] 中提供了一种对金融风险知识图谱的动态关系进行预测的方法,主要采用无监督的语言模型作为训练任务,对输入进行特征提取后,然后学习命名实体间的关系,保证实体间关系及时进行更新。

### 5.2.3 网络客服

随着信息化程度的不断提高,信息的便捷性已成为全社会共同的关注点。在阿里智能客服中,知识图谱被用来将问题分类并自动匹配最佳答案,从而提高客服效率和质量,减轻人工客服压力。知识图谱可以让机器根据用户输入的问题,自动分析其意图,并提供针对性的解答,从而更快捷地解决用户问题。此外,知识图谱还可以整合企业内部和外部的知识资源,丰富答案库,提高客服能力和满意度。利用知识图谱补全技术构建智能对话系统,可以自动识别用户问题并回答,大幅提高客服效率和用户满意度。

### 5.2.4 新闻

一般情况下,新闻具有时效性和公开性,新闻语言还具有高度的简洁性。针对某个话题和事件,挖掘社交媒体和新闻媒体中的信息,利用知识图谱补全技术,对新闻进行舆情分析,为政府、企业等部门提供决策依据。

除了以上具体应用场景,知识图谱补全在其他场景的应用也被越来越多地关注和探索,例如智能教育、智能家居等。

## 6 问题与挑战

随着网上知识图谱应用的不断扩展和深入,知识图谱补全成为人工智能领域中研究的热点。然而,知识图谱补全也面临着一些问题和挑战。

### 6.1 知识图谱稀疏问题

知识图谱中描绘的现实世界是庞大且复杂的,知识图谱只覆盖了其中的一部分,故存在稀疏问题。知识图谱补全的目标之一就是增加知识图谱的完整性,使其更好地反映现实世界。但面对如此巨大负责的世界,从非结构化数据中获得有价值的信息,这仍然是目前一个不小的挑战。

### 6.2 关系推理难度大

知识图谱中关系是实体之间的交互,而且关系的构成和表达通常非常复杂。此外,关系之间也可能存在歧义或冲突。因此,从知识图谱补全的角度来看,如何对未知实体之间的关系准确推理出来是一个核心难题。

### 6.3 知识表示学习

知识表示学习是在已有的知识图谱中找出有效的表示形式,并为其赋予语义,使得它可以在其他任务中使用的技术。知识表示学习是知识图谱补全的关键。然而,如何对不同的知识进行有效的表示,是当前的一个重要问题。

### 6.4 性能问题

受限于当前的硬件和算法水平,现有的知识图谱补全技术还存在较多的性能问题。一方面,出于处理数据和信息的需要,知识图谱往往具有使用非常大的规模和复杂性;另一方面,知识图谱补全需要能够高效地处理庞大的数据集,因此对知识图谱补全的技术提出了更高的要求。

综上所述,知识图谱补全的技术与应用还面临着诸多瓶颈与挑战,这也对理论探索和技术研发提出了更高的要求,可以促进知识图谱补全技术的进一步发展与应用。

## 7 结束语

本文对面向深度学习的知识图谱补全模型进行了分析和讨论,讨论了目前的知识图谱补全模型各自存在的优缺点以及扩展模型。主要从有关深度学习的技术 3 个方面,对面向深度学习的知识图谱补全模型进行了分析总结。指出了目前知识图谱所面临的问题与挑战,并介绍了知识图谱在领域上的重要应用以及知识图谱在医疗、金融、网络客服、新闻等行业具体的应用场景。

知识图谱的发展目前一共经历了 5 个阶段,从早期的知识表示到专家系统时代,从万维网的兴起到群体智能时代,最终发展为如今的知识图谱。知识图谱发展历程如图 10 所示。

知识图谱具有广泛的应用前景和巨大的发展潜力。随着人工智能和深度学习技术的不断进步,知识图谱可以为不同领域带来更高效且智能的解决方案,可以为决策支持

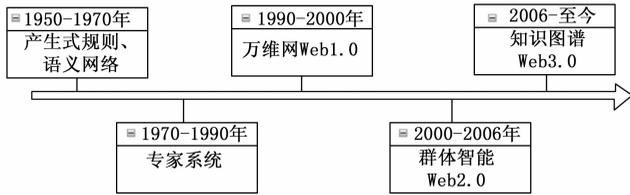


图 10 发展历程

系统提供更全面和准确的知识, 可以为搜索引擎和智能助手提供更准确和全面的结果。知识图谱将在各个领域应用中的持续发展和创新。

未来, 拥有强大算力的深度学习与拥有海量知识的知识图谱两种智能技术的深度融合将成为一种趋势, 更多的知识源会被整合到知识图谱中。由于知识图谱的不完整性, 有关知识图谱补全的方向将会是一个具有研究价值的热点。

#### 参考文献:

- [1] JI S, PAN S, CAMBRIA E, et al. A survey on knowledge graphs: representation, acquisition, and applications [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 33 (2): 494 - 514.
- [2] AMIT S. Introducing the knowledge graph [R]. America: Official Blog of Google, 2012.
- [3] MOHAMED S K, NOVÁČEK V, NOUNU A. Discovering protein drug targets using knowledge graph embeddings [J]. Bioinformatics, 2019, 36 (2): 603 - 610.
- [4] SONG W, WANG S, WANG Y, et al. A counterfactual collaborative session-based recommender system [C] // Proceedings of the ACM Web Conference 2023, 2023: 971 - 982.
- [5] LI T, WANG W, LI X, et al. Embedding uncertain temporal knowledge graphs [J]. Mathematics, 2023, 11 (3): 775.
- [6] ZHOU H, SHEN T, LIU X, et al. Survey of knowledge graph approaches and applications [J]. Journal on Artificial Intelligence, 2020, 2 (2): 89 - 101.
- [7] 张正航, 钱育蓉, 行艳妮, 等. 知识表示学习方法研究综述 [J]. 计算机应用研究, 2021, 38 (4): 961 - 967.
- [8] 张天成, 田 雪, 孙相会, 等. 知识图谱嵌入技术研究综述 [J]. 软件学报, 2023, 34 (1): 35.
- [9] BARTOLI E, ARGENZIANO F, SURIANI V, et al. Knowledge acquisition and completion for long-term human-robot interactions using knowledge graph embedding [C] // International Conference of the Italian Association for Artificial Intelligence, Cham: Springer International Publishing, 2022: 241 - 253.
- [10] ROSSI A, BARBOSA D, FIRMANI D, et al. Knowledge graph embedding for link prediction: A comparative analysis [J]. ACM Transactions on Knowledge Discovery from Data (TKDD), 2021, 15 (2): 1 - 49.
- [11] 杨大伟, 周 刚, 卢记仑, 等. 基于知识表示学习的知识图谱补全研究综述 [J]. 信息工程大学学报, 2021, 22 (5): 8.

- [12] ZAMINI M, REZA H, RABIEI M. A review of knowledge graph completion [J]. Information, 2022, 13 (8): 396.
- [13] ARORA S. A survey on graph neural networks for knowledge graph completion [J]. ArXiv Preprint ArXiv: 2007.12374, 2020.
- [14] JIN H, LI C, ZHANG J, et al. XLORE2: large-scale cross-lingual knowledge graph construction and application [J]. 数据智能 (英文), 2019, 1 (1): 22.
- [15] NSL D I. OpenKG chain: a blockchain infrastructure for open knowledge graphs [J]. Data Intelligence, 2021, 3 (2): 205 - 227.
- [16] XU B, LIANG J, XIE C, et al. CN-DBpedia2: an extraction and verification framework for enriching chinese encyclopedia knowledge base [J]. 数据智能 (英文), 2019, 1 (3): 18.
- [17] MILLER G A. WordNet: a lexical database for English [J]. Communications of the ACM, 1995, 38 (11): 39 - 41.
- [18] VRANDECIC D. Wikidata: a new platform for collaborative data collection [C] // Proceedings of the 21st International Conference on World Wide Web, 2012: 1063 - 1064.
- [19] BOLLACKER K, EVANS C, PARITOSH P, et al. Freebase: a collaboratively created graph database for structuring human knowledge [C] // Vancouver, Canada: Association for Computing Machinery, 2008: 1247 - 1250.
- [20] EHRLINGER L, WÖß W. Towards a definition of knowledge graphs [J]. SEMANTICS, 2016, 48 (1/2/3/4): 2.
- [21] MITCHELL T, COHEN W, HRUSCHKA E, et al. Never-ending learning [J]. Communications of the ACM, 2018, 61 (5): 103 - 115.
- [22] SOCHER R, CHEN D, MANNING C D, et al. Reasoning with neural tensor networks for knowledge base completion [J]. Advances in Neural Information Processing Systems, 2013, 26.
- [23] BORDES A, GLOROT X, WESTON J, et al. A semantic matching energy function for learning with multi-relational data [J]. Machine Learning, 2014, 94 (2): 233 - 259.
- [24] 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.
- [25] LIU Q, JIANG H, EVDOKIMOV A, et al. Probabilistic reasoning via deep learning: neural association models [J]. ArXiv Preprint ArXiv: 1603.07704, 2016.
- [26] NGUYEN D Q, NGUYEN T D, NGUYEN D Q, et al. A novel embedding model for knowledge base completion based on convolutional neural network [J]. ArXiv Preprint ArXiv: 1712.02121, 2017.
- [27] DETTMERS T, MINERVINI P, STENETORP P, et al. Convolutional 2d knowledge graph embeddings [C] // Proceedings of the AAAI Conference on Artificial Intelligence, 2018, 32 (1).

- [28] FENG W, ZHA D, WANG L, et al. Convolutional 3D embedding for knowledge graph completion [C] // 2022 IEEE 25th International Conference on Computer Supported Cooperative Work in Design (CSCWD), IEEE, 2022: 1197–1202.
- [29] JIANG X, WANG Q, WANG B. Adaptive convolution for multi-relational learning [C] // Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers), 2019: 978–987.
- [30] VU T, NGUYEN T D, NGUYEN D Q, et al. A capsule network-based embedding model for knowledge graph completion and search personalization [C] // Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers), 2019: 2180–2189.
- [31] VASHISHTH S, SANYAL S, NITIN V, et al. Interact: improving convolution-based knowledge graph embeddings by increasing feature interactions [C] // Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34 (3): 3009–3016.
- [32] SCARSELLI F, GORI M, TSOI A C, et al. The graph neural network model [J]. IEEE Transactions on Neural Networks, 2008, 20 (1): 61–80.
- [33] ZHOU J, CUI G, HU S, et al. Graph neural networks: a review of methods and applications [J]. AI Open, 2020, 1: 57–81.
- [34] BRUNA, JOAN, MALLAT, et al. Invariant scattering convolution networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35 (8): 1872–1886.
- [35] ZHOU J, CUI G, HU S, et al. Graph neural networks: a review of methods and applications [J]. AI Open, 2020, 1: 57–81.
- [36] 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, Springer International Publishing, 2018: 593–607.
- [37] YANG B, YIH W, HE X, et al. Embedding entities and relations for learning and inference in knowledge bases [J]. ArXiv Preprint ArXiv: 1412.6575, 2014.
- [38] CAI L, YAN B, MAI G, et al. TransGCN: coupling transformation assumptions with graph convolutional networks for link prediction [C] // Proceedings of the 10th International Conference on Knowledge Capture, 2019: 131–138.
- [39] SHANG C, TANG Y, HUANG J, et al. End-to-end structure-aware convolutional networks for knowledge base completion [C] // Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33 (1): 3060–3067.
- [40] VASHISHTH S, SANYAL S, NITIN V, et al. Composition-based multi-relational graph convolutional networks [J]. ArXiv Preprint ArXiv: 1911.03082, 2019.
- [41] YU D, YANG Y, ZHANG R, et al. Knowledge embedding based graph convolutional network [C] // Proceedings of the Web Conference 2021, 2021: 1619–1628.
- [42] 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, Springer International Publishing, 2018: 593–607.
- [43] VELICKOVIC P, CUCURULL G, CASANOVA A, et al. Graph attention networks [J]. Stat, 2017, 1050 (20): 10.48550.
- [44] WANG X, HE X, CAO Y, et al. Kgat: knowledge graph attention network for recommendation [C] // Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 2019: 950–958.
- [45] NATHANI D, CHAUHAN J, SHARMA C, et al. Learning attention-based embeddings for relation prediction in knowledge graphs [J]. ArXiv Preprint ArXiv: 1906.01195, 2019.
- [46] JI K, HUI B, LUO G. Graph attention networks with local structure awareness for knowledge graph completion [J]. IEEE Access, 2020, 8 (99): 1.
- [47] LIU X, TAN H, CHEN Q, et al. RAGAT: relation aware graph attention network for knowledge graph completion [J]. IEEE Access, 2021 (99): 1.
- [48] WANG Q, HUANG P, WANG H, et al. Coke: contextualized knowledge graph embedding [J]. ArXiv Preprint ArXiv: 1911.02168, 2019.
- [49] DEVLIN J, CHANG M W, LEE K, et al. Bert: pre-training of deep bidirectional transformers for language understanding [J]. ArXiv Preprint ArXiv: 1810.04805, 2018.
- [50] YAO L, MAO C, LUO Y. KG-BERT: BERT for knowledge graph completion [J]. ArXiv Preprint ArXiv: 1909.03193, 2019.
- [51] LIU W, ZHOU P, ZHAO Z, et al. K-BERT: enabling language representation with knowledge graph [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34 (3): 2901–2908.
- [52] LI D, YI M, HE Y. Lp-bert: multi-task pre-training knowledge graph bert for link prediction [J]. ArXiv Preprint ArXiv: 2201.04843, 2022.
- [53] ZOU X. A survey on application of knowledge graph [C] // Journal of Physics: Conference Series, IOP Publishing, 2020, 1487 (1): 012016.
- [54] KO H, LEE S, PARK Y, et al. A survey of recommendation systems: recommendation models, techniques, and application fields [J]. Electronics, 2022, 11 (1): 141.
- [55] LI L, WANG P, YAN J, et al. Real-world data medical knowledge graph: construction and applications [J]. Artificial Intelligence in Medicine, 2020, 103: 101817.
- [56] 张志剑, 倪珍妮, 刘政昊, 等. 面向金融知识图谱的动态关系预测方法研究 [J]. 数据分析与知识发现, 2023 (9): 39–50.