

基于知识图谱的6G网络场景认知研究

赵茁乔¹, 承楠¹, 陈劼², 陈芳炯³, 李长乐¹

(1. 西安电子科技大学通信工程学院, 陕西 西安 710071;

2. 电子科技大学通信抗干扰技术国家级重点实验室, 四川 成都 610054;

3. 华南理工大学电子与信息学院, 广东 广州 510640)

摘要: 6G网络覆盖空天地海全域, 对于多样化、个性化的场景, 6G网络需要提供定制化的服务, 即按需服务。为实现全域全场景的按需服务, 对场景特性进行精准、实时、智能的认知是一个重要前提。如何使网络自主智能地认知不同的场景及服务并将认知结果转换成场景特定的网络关键性能指标, 并进一步对网络资源进行高效调度是亟待解决的关键问题。为此, 将知识图谱应用于网络场景的认知识别, 形成对6G网络场景的规范化描述, 并构建了基于6G场景本体的知识图谱。同时, 提出一种基于知识图谱嵌入的场景认知推理方法, 实现了对图谱节点和关系的嵌入学习, 并对场景特征节点进行了预测推理, 取得了较高的准确度。该方法有助于实现6G全场景网络中场景感知、认知、按需服务的服务全生命周期自主管控, 对于提高下一代网络的自主性和智能性有重要的指导意义。

关键词: 6G全场景; 场景认知; 知识图谱; 图嵌入; 节点预测

中图分类号: TP391.1

文献标志码: A

doi: 10.11959/j.issn.2096-6652.202339

Research on 6G network scenario cognition based on knowledge graph

ZHAO Zhuoqiao¹, CHENG Nan¹, CHEN Jie², CHEN Fangjiong³, LI Changle¹

1. College of Communication Engineering, Xidian University, Xi'an 710071, China

2. National Key Laboratory of Communication, University of Electronic Science and Technology of China, Chengdu 610054, China

3. School of Electronics and Information Engineering, South China University of Technology, Guangzhou 510640, China

Abstract: The 6G network covers the entire space, air, ground, and sea. For diversified and personalized scenarios, the 6G network needs to provide customized services, that is, on-demand services. In order to realize on-demand services in all domains and scenarios, accurate, real-time, and intelligent cognition of the characteristics of the scenarios is an important prerequisite. How to enable the network to autonomously and intelligently recognize different scenarios and services, convert them into scenario-specific network key performance indicator (KPI), and further efficiently schedule network resources is a key problem that urgently needs to be solved. This paper applies the knowledge graph to the cognitive recognition of network scenarios, forms a standardized description of 6G network scenarios, and builds a knowledge graph based on the 6G scenario ontology. At the same time, a scene cognition reasoning method based on knowledge graph embedding is proposed, which realizes the embedding learning of graph nodes and relationships and reasons about scene feature nodes, achieving high accuracy. The method proposed in this paper helps to realize the autonomous control of the service life cycle of scene awareness, cognition, and on-demand services in the 6G full-scenario network, and has important innovation and guiding significance for improving the autonomy and intelligence of the next-generation network.

收稿日期: 2023-02-23; 修回日期: 2023-05-02

通信作者: 承楠, dr.nan.cheng@ieec.org

基金项目: 国家重点研发计划 (No.2020YFB1807700)

Foundation Item: National Key Research and Development Program of China (No.2020YFB1807700)

Key words: 6G full scenario, scenario cognition, knowledge graph, graph embedding, node prediction

0 引言

在下一代6G网络中,网络的覆盖范围将在广度和深度两个维度得到进一步扩展,将以地面通信网络为基础,结合太空和海洋通信,形成全地形、全空间立体覆盖的空天地海一体化全域泛在通信网络^[1]。同时,新一代信息技术,如人工智能、云计算、大数据等也在加速与通信网络全面融合。这些都将使得网络场景和应用得到极大的丰富,也会使用户对网络的关键性能指标(key performance indicator, KPI)提出更多样化、更精确和更高的要求。IMT-2030推进组相较于5G中的三大传统应用场景,提出了沉浸式云扩展现实(extended reality, XR)、全息通信、感官互联、智慧交互、通信感知、普惠智能、数字孪生、全域覆盖等八大潜在应用场景^[2]。然而,在6G网络中,由于环境的异构性、复杂性和用户需求的多样性,必然还会存在不计其数的未知的应用场景。因此,在多源异构的全新场景下,如何为用户提供个性化定制化的服务以满足用户多样化的需求,即实现网络的按需服务,对于提高下一代6G网络的自主性与智能性有重要意义。

为了满足用户在任意场景下的多样需求,需构建一种可靠完善的6G全场景按需服务架构,而场景的认知和理解则是按需服务的必要环节和重要前提,在这一步中,需要通过高效精确的方法完成由已知部分的场景信息到完整详细的场景认知信息(如某项服务的KPI指标)的映射。在得到完整的场景认知信息后,便可以辅助网络进行资源的调配决策以满足用户个性化的多样需求,从而真正实现6G网络的按需服务。目前,已有一些特定通信场景下的认知研究,Cheng等人^[3]研究了在小样本条件下从通信网络的频谱数据中进行通信行为的识别,Zhou等人^[4]提出了一种基于多特征融合的高铁信道传播场景识别模型,并进行了此场景下的信道相关性分析,Wang等人^[5]提出了一种基于图像分类的频谱感知方案,以实现发射机运行场景的认知识别,为动态频谱接入的决策提供了帮助。但至今仍缺少在大规模网络场景下的认知方法。因此,本文将知识图谱应用于对全域全场景网络下的认知

与理解,基于构建的网络场景知识图谱并结合相应的知识图嵌入算法完成对场景特征信息的预测推理,实现对场景的认知和理解。

知识图谱是一种通过数据挖掘、信息处理、知识度量和图形绘制显示等多学科融合而成的复杂知识领域^[6],具有强大的领域知识表达和处理能力,如今在医学、商业、智能等多个领域都有广泛的应用且均取得了良好的效果。目前,有一些将知识图谱应用于通信领域中的实例,Bai等人^[7]提出了在多址边缘计算异构网络场景下的一种基于知识图谱的视频缓存方案。知识图谱作为反映用户偏好的外部知识来指导缓存决策。为帮助相关人员了解5G网络中各类通信协议和指标及其详细信息,Song等人^[8]提出了一种基于多元关系和时间依赖链的知识图谱构建方法,最终构建了5G通信协议知识图谱。但是,上述应用场景十分局限,也并未对通信场景的领域知识做规范化、全局性的定义和描述。本文对场景要素进行分解,提出了网络场景本体结构,划分了网络场景的范围,形成了对大规模网络场景的规范化完备描述,并基于此构建了完整的6G全场景知识图谱。

综上,本文首次将知识图谱技术应用于大规模网络场景的认知与理解。首先,提出了场景本体架构,初步形成了对通信场景的规范化描述,并依此构建出完整的6G全场景知识图谱,然后,结合几种高效的知识图嵌入算法完成对场景特征数据及数据间关系的嵌入,并对场景信息进行了预测,最终实现了对场景的认知和理解。这一过程将大大提升下一代网络的自主性和智能性。

1 场景本体

从结构而言,知识图谱可分为模式层与数据层,模式层构建在数据层之上^[9]。而知识图谱的模式层通常源于领域本体的构建,是知识图谱的概念模型和逻辑基础。本体是共享概念模型的明确的形式化规范^[10]。它规范了知识图谱的领域和范围,明确了各抽象概念之间的关系。根据模式层和数据层构建的先后顺序,知识图谱构建可分为自底向上和自顶向下两种方法。自底向上的方法先进行数据的抽取,然后再构建上层本体,自顶向下的方法先

根据专家经验构建本体,然后在本体的规范下为知识图谱添加实例。领域知识图谱知识深度深、精度高,对知识的准确性要求严格,常采用自顶向下的方法构建^[11]。因此本文亦采用自顶向下的方法完成场景知识图谱的构建。

本文结合相关专家知识,提出了如图1所示的6G全场景本体架构。6G全场景本体应由四部分组成:环境、资源、主体和服务。环境指场景所依赖的现实世界的真实环境,资源指场景中可利用的各类资源,服务指场景能够满足的各类需求,主体指场景中有特定需求的用户。在不同的环境中需要给主体提供多样的服务。受环境的影响,资源可能有多样性的存在和分布形式,是否能为用户提供相应的服务取决于资源的合理分配。同时,这些组成部分又各有其特征,如主体的行为特征、环境的外在特征和服务的性能特征(KPI)等,可以从这些特征中获取某些信息数据用来指导方法,从而实现资源的合理分配,以达到为用户提供服务的目的。




图1 6G全场景本体架构

2 6G全场景知识图谱

知识图谱由模式层到数据层的实现过程即由抽象到具体的过程,场景本体规定了知识数据的类型、关系和范围,接下来就是用现实世界中真实数据去填充定义的框架。本文采用资源描述框架(resource description framework, RDF)中的三元组(实体—关系—实体或实体—属性—值)来保存数据及数据间的关系,本节将介绍场景图谱构建过程中实体和关系类型的选择、数据的来源及采集和图谱构建结果。

2.1 图谱实体及关系选择

根据提出的场景本体,我们选择如下几类实体作为6G全场景知识图谱的实体。

- 1) 场景类实体:包括现有所有的通信场景或者已经定义但未完全实现的通信场景。
- 2) 环境类实体:场景所处的现实环境。
- 3) 服务/需求类实体:在具体环境中各种具体的服务或用户需求。
- 4) 资源类实体:场景中的各类资源。
- 5) 主体类实体:场景中完成某个服务过程中的所有参与者。
- 6) KPI类实体:描述服务对应的具体的KPI。
- 7) 方法类实体:在各类通信环境中使用的技术,提出的各种策略或者解决方案。
- 8) 特征类实体:描述不同场景、不同环境、不同技术、不同需求或服务具有的各种属性。
- 9) 数据信息类实体:从场景、环境或者用户等处搜集的状态信息。
- 10) 能力类实体:用来表示技术、设备、场景等所具有的完成某个目标的能力。

表1列举了本文在构建6G全场景知识图谱时对各类实体的选取样例。样例来源于6G相关综述或相关文献。

表1 实体类型样例

实体类型	举例
场景	URLLC, satellite network
环境	room, sea, highway
服务	education, sending a message
资源	bandwidth, IP address
主体	user, car, service provider
KPI	latency, reliability
方法	massive MIMO, tHz, digital twins
特征	temporal traffic variations
数据信息	rendering information
能力	achieve a Gbps-level

同时,为了详细准确地描述各类实体间的相互作用,本文使用了以下几类关系。

- (1) 继承类关系:表示一个实体是另一个实体的组成部分或是它的子类。
- (2) 属性类关系:描述实体具有的某些特征属性。
- (3) 需求类关系:表示实体间的需求关系。
- (4) 能力类关系:表示实体具有完成某个目的的能力类型。
- (5) 比较类关系:实体间的大小、性能等的对

比关系。

表2列举了构建图谱时对每种关系类型的选取样例。

表2 关系选择样例

关系类型	举例
继承类关系	is_part_of, subclass_of, is_a
属性类关系	has_scenario, has_KPI
需求类关系	solution_of, require, purpose
能力类关系	cause, limit, improve, capable_of
比较类关系	higher, equal, larger

2.2 数据来源及知识抽取方法

目前被广泛使用的知识图谱数据一般来源于维基百科或者领域中公开的并具有高可信度的数据，所以在构建特定领域、用于特定任务的知识图谱时，数据源的质量十分重要。本文构建的6G全场景知识图谱使用的数据源及采集方法如图2所示。选取的数据源包括3GPP标准文档、6G相关综述以及学术论文等。以3GPP标准文档为例，本文选取了3GPP规定的5G网络标准下的应用场景，如车联网、无人机、高铁、音视频传输等多类应用场景，每一场景中都包含了几个具体的业务应用案例，其中均以文字、表格或图片的形式描述了该业务发生环境的特征信息以及此业务所服务的主体。图2左侧的数据源所展示的是标准文档中描述的有关触觉和多模态通信场景下的极致多模态VR服务的数据源。其中，文本数据和图片数据描述了此场景发生的环境背景、用户的需求和状态特征信息，表格数据规定了此场景下对于该服务的一些KPI指标的具体数值，如时延、数据速率、可靠性等。

如图2所示，在获得了可靠的数据源后，本文

通过手动提取、自动抽取并结合专家知识从这些非结构和半结构化的数据中抽取结构化的场景数据，再将其转化为固定形式的知识图谱三元组，以完成知识的抽取环节。对于非结构化的文本类型数据，本文借助基于BiLSTM-CRF^[12]模型的命名实体识别任务进行关键实体的抽取。首先对文本段落进行整句分割，并采用BMES (begin, middle, end, single)标注体系对获得的单句进行手动标注构建语料库，之后使用语料库对模型进行训练，最后用训练好的模型从新的场景文本中抽取需要的实体。对于半结构化的表格类型数据，本文通过基于规则和专家知识的方法进行抽取，匹配选取符合要求的表头（如图2表格数据中表头名为KPI的数据列），对关键的数据行或数据列进行完整的提取。

另外，本文在抽取知识时并没有对实体的关系进行抽取，本文将抽取的所有实体数据都以键值对的形式存储，键的名称均为第2.1节中定义的实体类型。之后会根据实体数据的键名称自动生成实体数据间的关系。如图2右侧所示的一组场景数据中，KPI数据都存储在键名称为“KPI”的列表中，之后和此场景数据中键名称为“Service”的数据生成“has_KPI”的关系，并以知识三元组的形式存储。最终，通过上述方法，本文实现了由非结构和半结构化数据到结构化知识三元组的转化。

2.3 场景图谱构建结果

目前构建知识图谱的主流方法是使用Neo4j图数据库，其提供了面向图分析的Cypher语言，具有可用性高、数据冗余低和吞吐量等特点^[13]，其在结构化图数据的管理与分析中有明显的优势，所以本文也使用Neo4j数据库实现6G全场景知识图谱的构建。在第2.2节中本文从各类语料中提取




图2 数据来源及结构化数据的抽取方法

表3 6G全场景知识图谱部分节点类属性

类名	类属性
主体	{id, name, UE_state, UE_type, priority, access}
环境	{id, name, network_type, service_area, density}
服务	{id, name}
KPI	{id, name, value}

这样在获得一组新的场景数据时，就可以用此模型去预测推理一些未知但必要的场景信息。如图4所示，已有一个6G全场景知识图谱，此时的数据虽




图4 基于知识图嵌入的场景预测

3.1 知识图嵌入模型

知识图谱在表示结构化数据方面有巨大优势，但这种符号化表示的三元组数据通常在实际中难以应用。为解决这一问题，知识图嵌入被引入并获得了大量关注，其通过学习知识图谱中实体和关系在向量空间中的嵌入，对知识图谱中的语义信息进行向量化表示^[14]。嵌入后的实体和关系可以方便地用于各类下游任务中，如知识图补全、关系提取和命名实体识别等。典型的知识图嵌入技术通常有3步：表示实体和关系、定义评分函数、学习实体和关系表示^[15]。第一步是完成实体和关系在连续向量空间的初始化表示，此时的实体和关系都是独立的向量，并没有关系。第二步定义评分函数的目的是评估一个三元组的合理性，能在知识图谱中观测到的三元组往往比未知的三元组有更高的函数值。第三步是一个优化问题，即基于第二步中的评分函数最大化观测到的三元组来完成实体和关系的嵌入。

目前已提出了很多的嵌入技术，本文将主要介绍所使用的几种平移距离嵌入模型，它利用基于距离的评分函数，通过经关系翻译后的头尾实体间的距离来衡量一个三元组的合理性。

3.1.1 TransE模型

TransE模型^[16]是经典的平移距离模型，它将实体和关系均嵌入在同一个低维向量空间中，将关

然以图的形式连接在一起，但数据本身还是独立的，并没有和周围的数据节点进行交互，需要使用知识图嵌入模型实现对每个节点的嵌入，即让每个节点都能聚合相邻甚至多跳节点的信息，挖掘数据间特征的影响关系。之后，若从新的场景环境中收集到一些外在的特征数据，便可以通过嵌入后的知识图谱去推理未知的信息，如此场景下某项服务的KPI指标的具体数值、可能存在哪些需求主体等，最终实现对场景的认知和理解。

系解释为在实体上的平移翻译操作，嵌入后的头尾实体可以通过关系以低误差连接。具体来说，给定一个正确的三元组 (h, r, t) ，尾实体 t 的嵌入应该等于头实体 h 加上关系 r 。如图5(a)所示，对于一个三元组(video, has_KPI, latency)，嵌入后实体和关系向量应满足 $\text{video} + \text{has_KPI} = \text{latency}$ ，对应的语义为时延是视频这项服务的KPI指标。




图5 TransE模型

TransE模型的评分函数为：

$$f_r(h, t) = -\|h + r - t\|_{l_2} \quad (1)$$

为了学习上述嵌入，模型在训练集上最小化了基于边际的排名标准：

$$L = \sum_{(h, r, t) \in S} \sum_{(h', r, t') \in S'_{(h, r, t)}} [\gamma + d(h + r, t) - d(h' + r, t')]_+ \quad (2)$$

其中， (h', r, t') 为根据原三元组生成的损坏三元组，每次只在所有实体中随机选择替换头实体或尾实体， γ 为边际超参数， $d(h + r, t)$ 为三元组的距离函数，由

式(1)决定。可见,式(2)通过优化正确三元组和错误三元组的距离来实现实体及关系的嵌入。

虽然 TransE 模型是一种简单高效的嵌入模型,但其在处理一对多和多对多关系时表现并不理想。以图 5(b)为例,由于模型将所有实体和关系都表示在同一向量空间,当实体 video 有多个 KPI 指标时,将无法有效地训练多个 KPI 实体,可能会导致实体 latency 和实体 bit rate 由同一个向量表示,这并不是一个理想的结果。

3.1.2 TransH 模型

为了解决 TransE 模型在处理一对多/多对一/多对多关系时的问题,TransH 模型^[17]将关系建模在超平面上,使实体在涉及不同关系时具有分布式表示。如图 6 所示,关系 has_KPI 位于超平面上,首先将所有实体投影到此超平面上,再将关系解释为实体在超平面上的翻译操作。可以看出,在一对多关系中虽然实体在超平面上的投影被表示为同一向量,但在实体的嵌入空间却有不同表示。另外,每一种关系都有独自的超平面投影向量和在超平面上的嵌入向量。




图6 TransH 模型

假设关系对应的超平面为 w_r , 关系的嵌入向量为 d_r , 则实体在超平面的投影为:

$$h_{\perp} = h - w_r^T h w_r, t_{\perp} = t - t_r^T h t_r \quad (3)$$

此时,其评分函数为:

$$f_r(h, t) = \left\| (h - w_r^T h w_r) + d_r - (t - t_r^T h t_r) \right\|_2^2 \quad (4)$$

在 TransH 中,通过将投影引入特定关系超平面的机制,使得实体在不同的三元组中扮演不同的角色。其损失函数和训练方法与 TransE 相同。另外,模型在克服了 TransE 模型缺陷的同时保持了与 TransE 模型相同的复杂度^[14]。

3.1.3 TransR 模型

在 TransE 和 TransH 模型中,实体和关系均在

同一个语义空间中完成嵌入。然而事实上,一个实体可能包含多个方面,不同的关系会关注实体的不同方面,这使得仅仅一个公共的空间不足以为实体和关系建模。为了解决上述问题,TransR 模型将实体和关系分开,在不同的空间(实体空间和多个特定关系空间)中构建实体和关系的嵌入,并在相应的关系空间中执行翻译完成嵌入^[18]。如图 7 所示,首先为实体和关系在不同的空间中建模,然后,使用特定于关系的投影矩阵 M_r (即 has_KPI 这一关系特定的矩阵,若关系不同,则投影矩阵亦不同)将实体投影至关系空间,最后在关系空间完成翻译嵌入。




图7 TransR 模型

每个关系都有其对应的投影矩阵 M_r , 实体在关系空间的投影向量可表示为:

$$h_r = h M_r, t_r = t M_r \quad (5)$$

其评分函数为:

$$f_r(h, t) = \|h_r + r - t_r\|_2^2 \quad (6)$$

TransR 模型的训练方法和 TransE 模型相同。可以看出 TransR 模型在处理一对多关系时也有良好的表现,但由于它为每个关系都引入了投影矩阵,其参数大小为关系维度和实体维度的乘积。所以,TransR 相较 TransE 和 TransH 模型,其模型复杂度更高,训练效率更低。

3.2 基于 BERT 的场景知识嵌入模型

6G 网络场景包含环境、主体、服务等多元特征信息,这些外在特征相互作用共同决定了场景的深层次特征。但上述模型每次训练时只能处理一对实体或实体属性的语义特征,无法同时提取多项特征的上下文信息。针对上述问题,本文提出了如图 8 所示的一种基于 Transformer 的双向编码器表征(bidirectional encoder representations from transformers, BERT)^[19]的知识嵌入模型,将一个三元组中实体的所有属性特征和关系转化为文本序列输入至模型,以实现从全局的角度学习场景的深层次特征。

BERT 是一种预训练的语言模型,因其能够有

效地学习文本序列的上下文语义信息而在各类自然语言处理任务中表现出优异的性能。图8中输入序列的格式遵循了BERT模型的序列生成规范,均以特殊字符[CLS]开头,头实体被表示为包括名称在内的当前实体所有属性的文本序列。例如图8中的主体实体human被重新表示为{human, VR, equipment, Stationary, or, Pedestrian, 3, WLAN},关系依然使用原三元组中的相关描述,尾实体的表示方法和头实体相似,如图8中的环境实体indoor被表示为{indoor, 5G, network, <100 km², Null}。实体和关系间通过特殊字符[SEP]分开。通过上述方法,最终的输入序列可表示为{CLS, human, VR, equipment, Stationary, or, Pedestrian, 3, WLAN, SEP, Is_in, SEP, indoor, 5G, network, <100 km², Null}。

对于以上序列,输入向量的形式依然遵循Devlin等^[19]的构造方法,由对应的词向量、段向量和位置向量求和组成。词向量可从一些预训练的词向量模型中获得,也可以随机初始化词向量。通过SEP分隔开的序列有不同的段向量,同一段内的字符共享相同的段向量。图8中的序列分为头实体、关系和尾实体3段,需要用3个不同的段向量表示。位置向量由当前字符在整个序列中的位置决定,同一位置的不同字符共享同一个位置向量。将3种向量求和获得输入字符的表示E,并将其送入BERT模型中进行训练。经过多个由多头注意力机制层和全连接神经网络层组成的编码块的特征提取,最终输出序列中每个字符的隐藏态向量。如图8所示,本

文将序列的起始标识符[CLS]对应的输出C作为计算三元组聚合特征的表示向量,并以三元组分类的方式对模型进行微调。模型的交叉熵损失函数为:

$$\text{loss} = - \sum_{\tau \in \mathcal{D}^+ \cup \mathcal{D}^-} (y_{\tau} \log(s_{\tau 0}) + (1 - y_{\tau}) \log(s_{\tau 1})) \quad (7)$$

其中, $\mathcal{D}^+$ 和 $\mathcal{D}^-$ 分别代表正例和负例样本集, $y_{\tau} \in (0, 1)$ 为三元组的预测标签。 $s_{\tau 0}, s_{\tau 1}$ 为模型最终输出的分类向量,并且 $s_{\tau 0} + s_{\tau 1} = 1, s_{\tau 0}, s_{\tau 1} \in [0, 1]$ 。

3.3 基于知识图谱链路预测的场景认知

本文采用知识图谱中的链路预测任务来实现对场景的预测认知。该任务首先在TransE中使用,其目的是预测事实三元组 (h, r, t) 中缺失的 h 或 t , 即给定 h 和 r 预测最可能的 t 或给定 r 和 t 预测可能的 h 。如图5(b)所示,假如此时收集到一组新的场景信息,我们想知道此场景下特定服务的KPI指标,就可以将已知信息作为头实体 h , 关系 r 为 has_KPI, 通过链路预测的方法预测可能的KPI指标 t , 最终实现对场景的理解认知。

3.3.1 评估方案和实验设置

在实验中,遵循TransE模型的评估规则,对于每一个测试三元组 (h, r, t) , 使用所构建知识图谱中的所有实体替换 t , 并根据评分函数计算每一个替换后三元组的分数,之后将分数按照升序排列得到原始正确实体的排名。本文一共选择两个指标来评估模型预测的准确度: 平均排名, 即所有测试集中正确实体的平均排名; 排名不超过10占比, 即所有三元组中实际正确实体的排名不超过10所占




图8 基于BERT的场景知识嵌入模型

比例,也可表示为Hits@10。在这两种指标中,平均排名越低越好,Hits@10的值越高越好。

同时,3种平移距离模型均有如下参数:学习率 α ,边际超参数 γ ,实体和关系嵌入维度 k ,为保证实验公平性,设置如下。

(1) TransE 模型: $\alpha=0.001, \gamma=1, k=10$ 。

(2) TransH 模型: $\alpha=0.001, \gamma=1, k=10$ 。

(3) TransR 模型: $\alpha=0.001, \gamma=1, \text{entity } k=10, \text{relation } k=6$ 。

本文所提出的基于BERT的模型的主要参数为:学习率 $\alpha=0.001$,文本最大长度 $l=30$,注意力头数 $n_heads=3$,编码块 $n_layers=3$,注意力维度 $Q_size=K_size=V_size=32$ 。

3.3.2 预测结果及分析

模型的预测结果如表4所示,可以看出TransE之后的两个优化模型,尤其是TransH模型在处理一对多/多对一/多对多/自反关系上有了明显的改善,这些改进可能来源于额外空间的引入,但会导致模型计算复杂度的增加。其中,TransR模型相较于原始模型的改进较小,虽然TransR模型将实体和关系空间分离,使得嵌入有丰富的语义信息,但存在大量一对多关系时可能并没有良好的表现,会受到实体和关系的嵌入维度、数据量的大小、数

据形式等因素的影响。本文提出的基于BERT的知识嵌入模型在Hits@10指标中取得了最高的预测准确率,平均排名指标略低于TransH模型,但其性能从整体上而言优于其他3个基线模型,说明了此模型对于场景认知的高效性。

4 知识图谱使能场景认知的潜在应用

通过知识表示学习模型的嵌入,使得网络能够借助知识图谱进行未知场景认知信息的预测推理,继而辅助网络在各类下游任务中做出精准、及时、智能的决策。本节以特殊地区的无人机服务场景为例,说明知识图谱使能的场景认知在其中的作用。

在一些特殊区域,需要利用无人机作为中继为用户提供持续的服务,可将其概括为无人机节点的接入问题,此类问题常使用基于强化学习的模型解决。然而,随着用户和无人机数量的增加,其动作和状态空间的规模也会随之增大,使得模型的训练时间增长,难以收敛,最终导致网络无法做出及时、准确的决策。如图9所示,若在每次做出动作前先获取用户及无人机的外在状态特征(如位置、剩余资源量、服务完成度等),并将其输入知识图谱中,通过知识图谱的嵌入预测输出当前场景的认知信息,用这些认知信息替换原有的状态集合,例如用预测出的适合接入的无人机集合替换初始的所有无人机集合,用预测出的深层次用户特征(如用户的满意度或对服务质量的需求)替换用户所有的状态特征,可有效地减少当前动作状态空间的规模,辅助网络更及时地进行决策。

表4 4种模型链路预测结果

模型	平均排名	Hits@10/%
TransE	19	58.3
TransH	10	71.7
TransR	18	60
BERT	11	82.86




图9 知识图谱辅助的基于强化学习的无人机接入选择

5 结束语

本文将场景知识图谱作为一种知识库融入下一代通信网络中,旨在赋予网络对场景的理解认知能力,以提高网络的灵活性和智能性。通过对场景要素进行分解并结合实际任务的需求,基本形成了对通信场景完备的规范化描述,并初步构建出包含人、无人机和车,涵盖大量现实场景的6G全场景知识图谱。最后,通过知识图谱中的链路预测任务举例验证了本文提出的场景认知方法,该方法取得了较为理想的结果。这是目前在大规模网络场景下以知识图谱技术使能场景认知的首次探索,对于此领域的进一步研究具有较高的借鉴意义。另外,本文目前仅完成了对网络场景的初步简单的认知,未来需要结合深度神经网络和先进的智能计算模型^[20],探索在多模态场景数据下对场景进行更精确、更全面、更本质的认知方法。

参考文献:

- [1] 赵亚军,郁光辉,徐汉青. 6G移动通信网络:愿景、挑战与关键技术[J]. 中国科学:信息科学, 2019, 49(8): 963-987.
ZHAO Y J, YU G H, XU H Q. 6G mobile communication networks: vision, challenges, and key technologies[J]. Scientia Sinica(Information), 2019, 49(8): 963-987.
- [2] IMT-2030推进组. IMT-2030(6G)推进组正式发布《6G总体愿景与潜在关键技术》白皮书[J]. 互联网天地, 2021(6): 8-9.
IMT-2030 Promotion Group. IMT-2030 (6G) Promotion Group officially released the white paper, "6G Overall Vision and Potential Key Technologies"[J]. China Internet, 2021(6): 8-9.
- [3] CHENG K X, ZHU L, YAO C H, et al. Squeeze-excitation based communication behavior recognition approach for spectrum sensing data [C]//Proceedings of 2021 7th International Conference on Computer and Communications (ICCC). Piscataway: IEEE Press, 2021: 682-686.
- [4] ZHOU T, WANG Y J, WANG C X, et al. Multi-feature fusion based recognition and relevance analysis of propagation scenes for high-speed railway channels[J]. IEEE Transactions on Vehicular Technology, 2020, 69(8): 8107-8118.
- [5] WANG Y, WANG X, SHEN B, et al. Clustering optimization and HOG feature extraction based primary user activity scene recognition scheme [C]//Proceedings of 2022 IEEE 95th Vehicular Technology Conference: (VTC2022-Spring). Piscataway: IEEE Press, 2022: 1-5.
- [6] 李建东, 杨晶晶, 黄铭. 基于知识图谱的Wi-Fi室内定位技术研究[J]. 物联网学报, 2022, 6(2): 19-25.
LI J D, YANG J J, HUANG M. Research on Wi-Fi indoor positioning technology based on knowledge graph[J]. Chinese Journal on Internet of Things, 2022, 6(2): 19-25.
- [7] BAI Y L, WANG D, SONG B. A knowledge graph-based cooperative caching scheme in MEC-enabled heterogeneous networks[C]//Proceedings of GLOBECOM 2022 - 2022 IEEE Global Communications Conference. Piscataway: IEEE Press, 2022: 5959-5964.
- [8] SONG G X, ZHENG M Z, XU H K, et al. Construction of 5G protocol knowledge graph based on multi-relation and sequential chain[C]//Proceedings of 2022 IEEE 2nd International Conference on Data Science and Computer Application (ICDSCA). Piscataway: IEEE Press, 2022: 1374-1377.
- [9] 徐增林, 盛泳潘, 贺丽荣, 等. 知识图谱技术综述[J]. 电子科技大学学报, 2016, 45(4): 589-606.
XU Z L, SHENG Y P, HE L R, et al. Review on knowledge graph techniques[J]. Journal of University of Electronic Science and Technology of China, 2016, 45(4): 589-606.
- [10] STUDER R. Knowledge engineering: principles and methods[J]. Data & Knowledge Engineering, 2008, 25(1-2): 161-197.
- [11] 牟天昊, 李少远. 流程工业控制系统的知识图谱构建[J]. 智能科学与技术学报, 2022, 4(1): 129-141.
MOU T H, LI S Y. Knowledge graph construction for control systems in process industry[J]. Chinese Journal of Intelligent Science and Technology, 2022, 4(1): 129-141.
- [12] HUANG Z, XU W, YU K. Bidirectional LSTM-CRF models for sequence tagging[EB]. arXiv preprint, 2015, arXiv:1508.01991.
- [13] LIU X Y, TAN H B, CHEN Q H, et al. RAGAT: relation aware graph attention network for knowledge graph completion[J]. IEEE Access, 2021, 9: 20840-20849.
- [14] 陈名杨, 张文, 陈湘楠, 等. 群体知识图谱: 分布式知识迁移与联邦式图谱推理[J]. 智能科学与技术学报, 2022, 4(1): 55-64.
CHEN M Y, ZHANG W, CHEN X N, et al. Collective knowledge graph: meta knowledge transfer and federated graph reasoning[J]. Chinese Journal of Intelligent Science and Technology, 2022, 4(1): 55-64.
- [15] 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.
- [16] BORDES A, USUNIER N, GARCIA-DURÁN A, et al. Translating embeddings for modeling multi-relational data[C]//Proceedings of the 26th International Conference on Neural Information Processing Systems - Volume 2. New York: ACM, 2013: 2787-2795.
- [17] WANG Z, ZHANG J W, FENG J L, et al. Knowledge graph embedding by translating on hyperplanes[C]//Proceedings of the Twenty-Eighth AAAI Conference on Artificial Intelligence. New York: ACM, 2014: 1112-1119.
- [18] LIN Y K, LIU Z Y, SUN M S, et al. Learning entity and relation embeddings for knowledge graph completion[C]//Proceedings of the Twenty-Ninth AAAI Conference on Artificial Intelligence. New York: ACM, 2015: 2181-2187.
- [19] DEVLIN J, CHANG M W, LEE K, et al. Bert: pre-training of deep bidirectional transformers for language understanding[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). [S.l.:s.n.], 2019: 4171-4186.

[作者简介]



赵苗乔 (1998-), 男, 西安电子科技大学通信工程学院硕士生, 主要研究方向为知识图谱在通信领域的应用。



承楠 (1987-), 男, 博士, 西安电子科技大学通信工程学院教授、博士生导师。主要研究方向为智能网联汽车与先进交通系统、无人驾驶、空天地一体化网络技术, 人工智能与大数据在网络中的应用, 5G、B5G、6G 先进网络技术与探索。



陈芳炯 (1975-), 男, 博士, 华南理工大学电子与信息学院教授、博士生导师。主要研究方向为无线通信及组网技术, 覆盖陆地及水下网络, 具体包括信道估计与均衡、新型调制技术、声电协同组网等。



陈劫 (1973-), 女, 博士, 电子科技大学通信抗干扰技术国家级重点实验室副研究员, 主要研究方向为认知无线电关键技术与应用及宽带多媒体集群。



李长乐 (1976-), 男, 博士, 西安电子科技大学通信工程学院教授、副院长、博士生导师。主要研究方向为网联网控无人驾驶、智能网联汽车超视距感知、交通大数据分析及应用、大规模网络技术、高动态网络技术等。