



计算机科学

COMPUTER SCIENCE

基于动态记忆和双层重构强化的知识图谱至文本转译模型

马廷淮, 孙圣杰, 荣欢, 钱敏峰

引用本文

马廷淮, 孙圣杰, 荣欢, 钱敏峰. 基于动态记忆和双层重构强化的知识图谱至文本转译模型[J]. 计算机科学, 2023, 50(3): 12-22.

MA Tinghuai, SUN Shengjie, RONG Huan, QIAN Minfeng. Knowledge Graph-to-Text Model Based on Dynamic Memory and Two-layer Reconstruction Reinforcement [J]. Computer Science, 2023, 50(3): 12-22.

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)

[融合多类时空轨迹特征的跨网络用户身份识别](#)

Cross-network User Identification Based on Multiple Spatio-Temporal Trajectory Features

计算机科学, 2023, 50(3): 114-120. <https://doi.org/10.11896/jsjcx.211200287>

[基于先验知识图谱的多代理被遮挡目标类别推理模型](#)

Novel Class Reasoning Model Towards Covered Area in Given Image Based on Informed Knowledge Graph Reasoning and Multi-agent Collaboration

计算机科学, 2023, 50(1): 243-252. <https://doi.org/10.11896/jsjcx.220700112>

[基于双向长短时记忆网络的企业弹性能力预测模型](#)

Prediction Model of Enterprise Resilience Based on Bi-directional Long Short-term Memory Network

计算机科学, 2022, 49(11): 197-205. <https://doi.org/10.11896/jsjcx.210900195>

[多轮对话技术及其在电网数据查询中的应用](#)

Multi-turn Dialogue Technology and Its Application in Power Grid Data Query

计算机科学, 2022, 49(10): 265-271. <https://doi.org/10.11896/jsjcx.200600078>

[基于Key-Value关联记忆网络的知识图谱问答方法](#)

Key-Value Relational Memory Networks for Question Answering over Knowledge Graph

计算机科学, 2022, 49(9): 202-207. <https://doi.org/10.11896/jsjcx.220300277>

基于动态记忆和双层重构强化的知识图谱至文本转译模型

马廷淮¹ 孙圣杰¹ 荣欢² 钱敏峰¹

1 南京信息工程大学计算机学院(软件学院、网络空间安全学院) 南京 210044

2 南京信息工程大学人工智能学院(未来技术学院) 南京 210044

(thma@nuist.edu.cn)

摘要 知识图谱转译文本(Graph-to-Text)是知识图谱领域中一个新的任务,旨在将知识图谱转化为描述该知识的可读性文本。随着近年来研究的不断深入,知识图谱转译文本的生成技术已经被应用于商品评论生成、推荐解释生成、论文摘要生成等领域。现有方法中的转译模型均采用先规划后实现的方式,未能根据已生成文本动态调整规划且未按静态内容规划对知识进行跟踪,导致文本前后语义不连贯。为了提高生成文本语义的连贯性,文中提出了基于动态记忆和双层重构强化的知识图谱至文本转译模型,通过静态内容规划、动态内容规划和双层重构机制这3个阶段,弥补了知识图谱与文本之间的结构化差异,在生成文本的同时侧重关注各三元组中的重要内容。与现有的生成模型相比,该模型不仅能缓解知识图谱与文本之间的结构化差异,还提高了定位关键实体的能力,从而使生成的文本具有更强的事实一致性和语义连贯性。在WebNLG数据集上进行了广泛实验,结果表明,在知识图谱转译文本的任务上,所提模型与现有模型相比,内容规划更加准确,生成文本语句间的逻辑合理且关联性更强,在BLEU, METEOR, ROUGE, CHRF++等指标上优于现有模型。

关键词: 知识图谱文本转译;自然语言生成;记忆网络;重构机制;结构化数据

中图法分类号 TP319.1

Knowledge Graph-to-Text Model Based on Dynamic Memory and Two-layer Reconstruction Reinforcement

MA Tinghuai¹, SUN Shengjie¹, RONG Huan² and QIAN Minfeng¹

1 School of Computer and Software, Nanjing University of Information Science and Technology, Nanjing 210044, China

2 School of Artificial Intelligence(School of Future Technology), Nanjing University of Information Science and Technology, Nanjing 210044, China

Abstract Knowledge Graph-to-Text is a new task in the field of knowledge graph, which aims to transform knowledge graph into readable text describing these knowledge. With the deepening of research in recent years, the generation technology of Graph-to-Text has been applied to the fields of product review generation, recommendation explanation generation, paper abstract generation and so on. The translation model in the existing methods adopts the method of first-plan-then-realization, which fails to dynamically adjust the planning according to the generated text and does not track the static content planning, resulting in incoherent semantics before and after the text. In order to improve the semantic coherence of generated text, a Graph-to-Text model based on dynamic memory and two-layer reconstruction enhancement is proposed in this paper. Through three stages of static content planning, dynamic content planning and two-layer reconstruction mechanism, this model makes up for the structural difference between knowledge graph and text, focusing on the content of each triple while generating text. Compared with existing generation models, this model not only compensates for the structural differences between knowledge graphs and texts, but also improves the ability to locate key entities, resulting in stronger factual consistency and semantics in the generated texts. In this paper, experiments are conducted on the WebNLG dataset. The results show that, compared with the current existing models in the task of Graph-to-Text, the proposed model generates more accurate content planning. The logic between the sentences of the generated text is more reasonable and the correlation is stronger. The proposed model outperforms existing methods on metrics such as BLEU, METEOR, ROUGE, CHRF++, etc.

到稿日期:2022-07-10 返修日期:2022-12-06

基金项目:国家自然科学基金(62102187);江苏省自然科学基金(基础研究计划)(BK20210639);国家重点研发计划(2021YFE0104400)

This work was supported by the National Natural Science Foundation of China(62102187), Natural Science Foundation of Jiangsu Province(Basic Research Program)(BK20210639) and National Key Research and Development Program of China(2021YFE0104400).

通信作者:荣欢(ronghuan@nuist.edu.cn)

Keywords Knowledge Graph-to-Text, Natural language generation, Memory network, Reconstruction mechanism, Structured data

1 引言


近年来,知识图谱逐渐流行,在从“感知智能”迈向“认知智能”的过程中扮演着重要角色。知识图谱由相互连接的节点和边组成,节点表示概念或者对象,边表示它们之间的关系。知识图谱可以由资源描述框架(Resource Description Framework, RDF)表示。RDF以三元组(subject, predicate, object)的形式描述实体与实体之间的关系或实体和属性的关系,这些关系即知识。知识图谱这种结构化数据可以容纳大量知识信息,无论是特定领域的专业知识或是日常生活中的常识信息都可以以知识图谱的形式保存,并且其应用范围广泛,如搜索引擎、金融风控、智能推荐、智慧客服等^[1]。知识图谱已经成为自然语言处理领域的热点^[2],对知识图谱进行研究具有重大意义。

知识图谱富含丰富的知识信息,而RDF等的表现形式极其复杂且可读性低^[3],非专业人员难以在短时间内清楚了解知识图谱包含的全部内容,并且人工将知识图谱转译为文本需要耗费大量的时间和精力。因此,产生了一个新的研究任务“知识图谱转译文本”(Graph-to-Text),旨在自动将输入的结构化知识图谱转化为描述这些知识的非结构化文本。例如,如图1所示,该三元组集形成了一个关于宇航员Alan Bean的知识图谱与其对应的描述文本。随着近年来研究的不断深入,知识图谱向文本转译的生成技术已经被应用于商品评论生成、推荐解释生成、论文摘要生成等场景。

Triples:

```
<Alan_Bean | birthDate | 1932-03-15>
<Alan_Bean | was a crew member of | Apollo_12>
<Alan_Bean | birthPlace | Wheeler, Texas>
<Alan_Bean | status | Retired>
```

Knowledge Graph:



Reference:

Alan Bean, who was part of Apollo 12, was born in Wheeler, Texas on March 15th, 1932 and is now retired.

图1 样例数据:知识图谱与其描述文本

Fig. 1 Example of data: knowledge graph and its description text

知识图谱、表格都属于结构化数据,Puduppully等^[4]将结构化数据转文本系统定义为3个独立的模块:1)内容规划,即选择将要描述的数据知识;2)句子规划,即决定所选数据知识在生成文本中的顺序;3)文本生成,即将句子规划的结果转化为文本。这3个阶段模拟写作过程确定写作内容、确定写作大纲和落笔写作,基本上成为了之后文本生成系统的范式。由此可见,转述信息的内容和组织规划对生成文本的效果都起到了至关重要的作用。现有的知识图谱转文本生成模型中,许多模型都在编码器中显式编码图结构,未对解码器进行进一步的改进,降低了解码器从编码结果中抽取关键信息的

能力,导致部分信息缺失。

针对上述问题,本文提出了一种基于内容规划机制与双层重构的知识图谱至文本转译模型。所提模型将内容规划与生成记忆相结合,追踪生成文本与静态内容规划的关系,把握句间描述重点的转移;提出双层重构机制,均以生成文本为出发点,重构静态规划并还原知识图谱,从多个角度引导解码器捕捉输入知识图谱的特征。

本文将基于“先内容规划后文本生成”的范式,采用端到端(End-to-End)的方式训练知识图谱至文本转译模型^[5-6],将其应用于WebNLG数据集^[7]。WebNLG数据集提供了知识图谱与对应的描述该知识图谱的参考文本,其中知识图谱由RDF三元组表示并且所有数据皆来源于DBpedia。与之前的模型相比,所提模型优于同类现有工作,其BLEU值达到了65.07, METEOR值达到了46.84, Rouge-L值达到了74.84。

综上所述,本文的贡献主要有以下3点:

(1)提出将静态内容规划与记忆模块结合,联系已生成文本信息调整记忆权重,选择符合上下文语境的“中心节点”,进一步生成与中心节点相关的词汇,提高上下文语义连贯性。

(2)为了充分利用解码之前各模块的信息,本文提出了基于双层重构驱动的解码器,促进解码器全面、准确地获取编码器中蕴含的本质特征,促进生成文本向静态内容规划对齐并提高生成文本与知识图谱的事实一致性。

(3)所提模型在WebNLG数据集上的表现优于之前的模型,内容规划更加准确,生成文本语句间的逻辑合理且关联性更强,在BLEU, METEOR, ROUGE, CHRF++等指标上优于现有方法,取得了最优效果。

本文第2节回顾了相关工作;第3节介绍了本文方法;第4节分析了实验结果;最后总结全文。

2 相关工作

知识图谱转译文本(Graph-to-Text)的问题属于结构化数据转译文本(Data-to-Text)问题下的一个分支,旨在将结构化数据转化为描述这些数据的可读性文本^[8]。结构化数据转译文本问题由来已久^[9],其中还包括表格转译文本(Table-to-Text)问题^[10]和抽象语义表示转译文本(AMR-to-Text)问题^[11]等,理解这些问题对本文研究也具有参考意义。现有方法均采用“编码器-解码器”的模型架构搭建知识图谱转译文本模型,可以将模型按照模型结构分为两类,即基于端到端结构(End-to-End)与基于流水线结构(Pipeline)。其中End-to-End是忽略具体化步骤,直接学习由输入到输出的映射,利用一个神经网络整合所有步骤;而Pipeline则将任务分解成多个子任务,并根据各子任务分别建立模块化神经网络。

2.1 基于端到端结构

2.1.1 基于序列到序列的网络

早期研究者将知识图谱进行线性处理,以融入图结构(Graph)信息,利用循环神经网络按三元组输入顺序对知识图谱进行编码。Distiawan等^[12]将知识图谱根据输入三元组的顺序展开成词汇序列编码。Li等^[13]提出了一种基于自适应指针

生成器网络的知识图谱转译模型,突出输入信息中的重点实体和重点关系。Chen 等^[14]利用自注意力机制对三元组中的字符进行层级编码,以获取三元组和实体嵌入,将图结构信息融入到三元组和节点表示中。Gao 等^[15]利用拓扑排序遍历图,运用循环神经网络对拓扑路径进行编码来反映图的拓扑结构信息,而将知识图谱按照三元组线性化排列处理,但仍然会丢失部分图结构信息。

2.1.2 基于图神经网络

随着图神经网络的兴起,研究者将图神经网络(Graph Neural Networks, GNN)^[16]与序列化模型相结合进行编码,有效利用了图结构信息。Guo 等^[17]通过深度图卷积网络(Graph Convolution Networks, GCN)捕获更多非局部信息,同时采用残差网络来保留局部信息进行编码。Beck 等^[18]采用了一种基于门控神经网络的编码器,它可以在不丢失信息的情况下整合完整的图结构。Koncel-kedziorski 等^[19]将图注意力机制(Graph Attention Networks, GAT)代替 Transformer 中的自注意力机制,将序列编码器应用于图结构化的输入。Shi 等^[20]在 GraphWriter 的基础上,根据图的邻接特征强化指针网络,从而提高已生成节点的邻接节点在后续解码步被选择的概率,并与覆盖损失函数相互配合,解决生成文本中信息重复或遗漏的状况。Gao 等^[21]分别对节点和关键路径进行编码,同时关注三元组内部信息和全局长范围依赖关系。Ribeiro 等^[22]运用 GAT,从局部和全局角度对知识图谱的节点编码并用 Transformer 生成文本。上述工作直接在原有知识图谱上采用图神经网络,重点关注知识图谱中的实体信息,但忽略了关系信息,丢失了部分语义信息。

2.1.3 基于预训练的语言模型

最近,大规模预训练语言模型因泛化效果好,微调速度快而受到越来越多研究者的青睐^[23]。大量工作^[24-26]显示, T5, BART 等预训练语言模型受益于在预训练或微调期间看到的类似事实,即使在少样本的情况下仍然能够表现优异。Ribeiro 等^[24]证明,大规模预训练语言模型即使未对图结构进行显式编码也能获得良好的效果。Li 等^[26]将预训练模型所得实体表示与图结构编码所获的实体表示对齐,并运用预训练语言模型 BART 生成文本,在小规模数据条件下也能生成描述准确的转译文本。而有工作证明,大规模预训练模型在语言的记忆能力、语言理解能力,甚至是其安全性方面还存在诸多缺陷^[27-28]。

2.2 基于流水线结构

Ferreira 等^[29]针对知识图谱转译文本任务,采用基于流水线结构(Pipeline)的神经网络模型进行内容规划后再进行文本生成,最终也能生成高质量的转译文本。因此,越来越多的研究者开始探索运用深度网络进行内容规划,将文本生成过程分解为内容规划阶段与文本实现阶段,以有效弥补了知识图谱结构化数据和文本非结构之间的差距^[30]。因此,本文模型将静态内容规划作为辅助任务,进一步深入研究内容规划对生成效果的影响。

2.2.1 静态内容规划

Moryossef 等^[31]将内容规划定义为树结构并用线性化方式表示,穷举所有可能的内容规划并根据 Product-of-Experts

(PoE)模型进行打分,选择最适合的规划。Zhao 等^[32]通过规划器生成内容规划,以弥补结构化数据和线性文本之间的差距,同时运用神经网络对所有节点编码获取全局信息,两种编码方式协同作用转译文本。Puduppully 等^[33-34]认为,待转译的结构化数据量较大时,句子级别的内容规划无法很好地选择内容与排序,因此提出段落规划策略,以学习更高级别的段落内部关系,从而提升文本转译质量。Shao 等^[35]针对转译文本词汇表达多样性不足的问题,将变分编码(Variational Encoder)引入内容规划阶段,增加长文本语句间的连贯性和表达的多样性。Su 等^[36]利用线性链条件随机场(Linear-Chain Conditional Random Fields)对三元组排序,并利用预训练语言模型 BART^[37]生成转译文本。

2.2.2 动态内容规划

动态内容规划建立在静态内容规划的基础上,根据已生成文本内容对规划顺序进行微调,使生成文本更加合理通顺。Chen 等^[38]在文本生成过程中根据生成内容动态修改输入数据的隐层表示。与先规划后生成不同, Iso 等^[39]利用循环神经网络进行追踪规划,在文本生成的过程中显式动态决定是否转移写作重点与选择要被提及的数据。而 Puduppully 等^[40]利用实体记忆机制在生成过程中调整各个实体的权重来确定重要描述实体。Shen 等^[41]将数据与文本进行对齐,生成文本时只关注对应的实体记录,便于控制输出文本的结构,从而逐段生成文本。

虽然上述方法都能生成较好的文本,但现有方法大多采用先规划后实现的方式,未能根据已生成文本信息对现有规划进行调整;或是将动态规划建立在静态规划的基础上,但未在文本生成过程中对静态内容规划进行跟踪,可能导致语义不连贯。本文提出的知识图谱至文本转译模型能够根据生成信息动态调整静态内容规划,根据记忆力机制捕捉符合上下文语义的“中心节点”,观察语句间的重点语义转换,以提高语句之间的连贯性。

3 基于动态记忆和双层重构强化的知识图谱至文本转译模型

3.1 任务定义

Graph-to-Text 任务旨在将知识图谱转译为准确描述该知识图谱的可读性文本,生成文本应语句通顺,尽可能反映所给知识图谱蕴含的全部知识信息并与给定知识图谱保持事实一致。本文以 RDF 数据表示知识图谱。输入为 RDF 三元组集合,其中三元组 $\langle \text{subject}, \text{predicate}, \text{object} \rangle$ 分别表示 \langle 主语, 谓语, 宾语 \rangle 。因此,定义知识图谱为三元组集合 $\{V_{tri}\}_{1-k}$, 三元组中包含 $\{V_{\text{subject}}, V_{\text{predicate}}, V_{\text{object}}\}_{1-k}$, k 为三元组个数。目标输出结果是描述该知识图谱的可读性文本,以 Reference 表示数据集给出的参考描述文本。例如,图 1 给出了宇航员 Alan Bean 的知识图谱与其对应的描述文本,并仿照数据集输入罗列了知识图谱包含的 RDF 三元组。

针对现有解码器抽取信息能力较弱而导致部分信息缺失的问题,本文提出了知识图谱至文本转译模型。首先对知识图谱进行内容规划,并根据记忆转移机制捕捉符合上下文语义的“中心节点”以动态调整内容规划,在生成文本后通过双层

重构机制引导解码器提取隐藏状态中关键信息的能力,保证解码器所获信息的准确性。Graph-to-Text 模型的整体架构如图 2 所示。数据集给出〈知识图谱-文本〉对,给定知识图谱中的事实数据,以三元组集合作为输入,通过静态内容规划、动态记忆解码和双层重构机制这 3 个阶段,根据所给定的数据事实产生描述该知识图谱的文本内容。

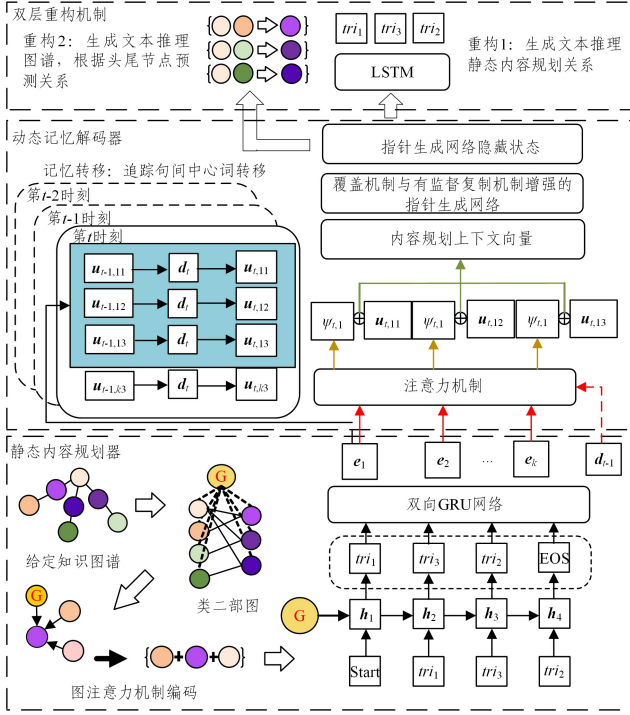


图 2 所提 Graph-to-Text 模型的整体架构图
Fig. 2 Graph-to-Text model architecture diagram

3.2 静态内容规划

静态内容规划是所提模型的第一阶段,如图 2 中的下半部分所示。静态内容规划可以分为两部分:第一部分为内容编码器,获取输入知识图谱中的实体和关系的表示;第二部分为静态内容规划器,清晰的内容规划有助于文本生成效果的提升,为模型指明描述的对象和描述顺序。

图 2 中,内容编码器将输入的知识图谱转化为类二部图(Bipartite Graph),即将原知识图谱中的关系转化为节点,将关系和节点以同样的方式进行编码。受 Koncel-kedziorski 等^[19]的工作的启发,向类二部图中加入了全局节点,将类二部图中的所有节点与全局节点相连接,使得对某一节点的

编码不仅仅关注该节点的邻接节点信息,同时也关注整个图的拓扑结构信息。因此,图谱可以定义为三元组集合 $\{V_{tri}\}_{1-k}$,三元组中包含 $\{V_{subject}, V_{predicate}, V_{object}\}_{1-k}$, k 为三元组的个数。由于类二部图的特性,将所有三元组中的实体和关系都定义到同一语义空间,均将其转化为节点,记为 $node$ 。内容编码器利用图注意力机制(Graph Attention Network, GAT)对类二部图编码,将关系和实体定义在同一表示空间内。GAT 通过自注意力机制对一阶邻居节点进行聚合,实现对不同邻居节点的权值自适应匹配,如式(1)一式(3)所示:

$$\alpha_{ij} = \text{Softmax}_j(\text{Att}(\mathbf{W} \cdot \mathbf{V}_{node_i}, \mathbf{W} \cdot \mathbf{V}_{node_j})) \quad (1)$$

$$\mathbf{V}_{node_i} = \sigma(\sum_{j=N_i} \alpha_{ij} \cdot \mathbf{W} \cdot \mathbf{V}_{node_j}) \quad (2)$$

$$\mathbf{V}_{tri_k} = \mathbf{V}_{subject_k} + \mathbf{V}_{predicate_k} + \mathbf{V}_{object_k} \quad (3)$$

其中, $node_j$ 为 $node_i$ 的一阶相邻节点, $\text{Att}(\cdot)$ 是利用注意力机制计算两个节点相关度的函数。在获得了权重系数 α 之后,仿照注意力机制加权求和的方式聚拢其他相邻节点信息,获取节点 i 的隐藏表示 \mathbf{V}_{node_i} 。内容编码器通过 GAT 获取实体和关系的表示,并且式(3)将三元组中实体和关系表示和作为三元组的表示。

静态内容规划器根据三元组内容进行排序,通过线性内容规划补足知识图谱结构化数据与文本非结构化之间的差距。规划器生成的三元组序列记作静态内容规划 SP 。静态内容规划阶段采用长短期记忆网络(Long Short-Term Memory, LSTM)生成三元组序列,在生成文本前规划描述文本需描述的内容及词语(节点)顺序。上一步选择的三元组表示作为下一步 LSTM 的输入,以全局节点表示 \mathbf{V}_{global} 作为初始隐藏状态。

$$P(SP_t = tri_k | \mathbf{h}_t, \mathbf{V}_{tri_k}) \propto \exp(\mathbf{h}_t \cdot \mathbf{W} \cdot \mathbf{V}_{tri_k}) \quad (4)$$

式(4)用于计算神经网络的隐藏状态 h_t 与第 k 个三元组表示 \mathbf{V}_{tri_k} 之间的相关性,表示下一步选择第 k 个三元组的可能性, SP 记为生成的静态内容规划序列。静态内容序列通过双向门控循环神经网络(Gate Recurrent Unit, GRU),将静态内容序列的前后序列关系融合到三元组表示中,如式(5)所示:

$$\mathbf{e}_{1-|SP|} = \text{BiGRU}(\mathbf{h}_{1-|SP|}) \quad (5)$$

其中, $|SP|$ 表示静态内容规划的序列长度。

3.3 动态记忆解码器

动态记忆解码是所提模型的第二阶段,如图 2 中的中间部分所示,具体如图 3 所示。

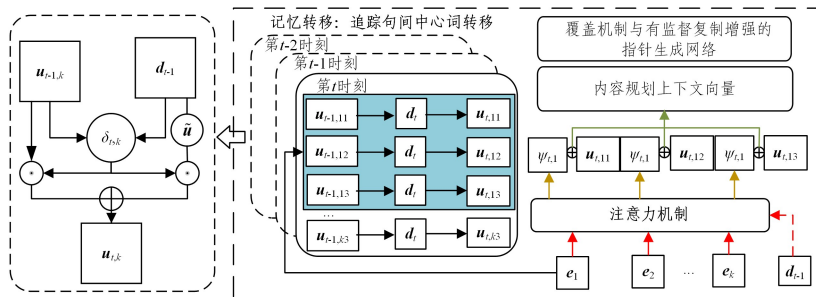


图 3 动态记忆解码器的结构

Fig. 3 Structure of dynamic memory decoder

传统的深度学习模型使用神经网络的隐藏状态或

注意力机制作为其记忆功能,但这些方法的记忆容量有限,无法

准确记录给定数据所表达的所有内容。也就是说,在将输入编码为密集向量时丢失了很多特征。而记忆网络能够显式记录显著内容,解码器可以在每个时间步从记忆网络中提取重要结点。

因此,本文将规划内容与记忆转移模块相结合。记忆模块用于存储固定时间窗口内的实体上下文,从而在解码的每一步引入动态调整后的上下文注意力权重,以判定当前解码位是否为上下文“中心节点”,并结合已生成文本信息调整记忆,从内容规划中捕获符合上下文语境的“中心节点”。

总体而言,记忆网络包括3部分:记忆更新、记忆抽取、循环迭代。本文中,记忆网络按规划顺序存储实体的内容,通过解码器的隐藏状态更新记忆内容,并使用注意力机制通过当下生成状态与三元组的关系实现记忆抽取。在每一个时间步循环上述记忆更新与抽取过程,以捕获符合上下文语境的“中心节点”。

为了在实体和关系层面进一步对描述重点进行细粒度捕获,记忆转移模块将三元组 $e_{1-|SP|}$ 映射实体和关系进行存储。首先,考虑到生成内容会动态影响静态规划,记忆网络利用生成解码器 LSTM 的隐藏状态 d_t 更新实体记忆 u ,具体如式(6)一式(10)所示:

$$u_{-1,k1}, u_{-1,k2}, u_{-1,k3} = \mathbf{W} \cdot \mathbf{e}_k \quad (6)$$

其中,式(6)利用静态内容规划序列的三元组隐藏表示 e 投影至每一个三元组中涉及到的实体和关系进行初始化记忆,记为 u_{-1} ,三元组在记忆模块中的存储顺序与静态内容规划的顺序一致, k 指代静态内容规划中的第 k 个三元组。记忆网络在每一个时间步均对记忆库中的所有内容进行更新。

$$\gamma_t = \text{Softmax}(\mathbf{W} \cdot \mathbf{d}_t + b_\gamma) \quad (7)$$

$$\delta_{t,k} = \gamma_t \odot \text{Softmax}(\mathbf{W} \cdot \mathbf{d}_t + \mathbf{b}_d + \mathbf{W} \cdot \mathbf{u}_{-1,k} + b_u) \quad (8)$$

式(7)结合生成部分的隐藏状态 d_t 计算门控 γ ,由门控 γ 决定记忆是否需要被修改;式(8)计算记忆 $u_{-1,k}$ 需要被修改的程度 $\delta_{t,k}$,由解码隐藏状态 d_t 和上一个时间步的记忆 $u_{-1,k}$ 决定。

$$\tilde{u}_{t,k} = \mathbf{W} \cdot \mathbf{d}_t \quad (9)$$

$$u_{t,k} = (1 - \delta_{t,k}) \cdot u_{-1,k} + \delta_{t,k} \cdot \tilde{u}_{t,k} \quad (10)$$

式(9)定义修改内容与解码隐藏状态 d_t 有关。式(10)根据修改内容 $\tilde{u}_{t,k}$ 与记忆修改程度 $\delta_{t,k}$ 对前一时刻的实体记忆 $u_{-1,k}$ 进行更新。

$$\Psi_{t,k} \propto \exp(\mathbf{d}_t^T \cdot \mathbf{W} \cdot \mathbf{e}_{t,k}) \quad (11)$$

$$\mathbf{q}_t = \sum_k \Psi_{t,k} [\mathbf{u}_{t,k1} + \mathbf{u}_{t,k2} + \mathbf{u}_{t,k3}] \quad (12)$$

式(11)通过注意力机制观察生成部分 LSTM 的隐藏状态 d_t 与静态内容序列的隐藏状态 e ,得到注意力系数 $\Psi_{t,k}$,该系数仍然停留在三元组层面,引导解码器关注重要的三元组。式(12)将三元组重要性系数 $\Psi_{t,k}$ 与对应三元组内部的记忆内容 $u_{t,k1}, u_{t,k2}, u_{t,k3}$ 相乘,得到记忆上下文向量 q_t 。记忆转移模块通过调整三元组的权重与修改记忆存储中实体关系内容,在生成文本的同时对静态内容规划进行调整。

在解码过程中引入图结构增强(Graph Structure Enhanced Mechanism, GSEM)的复制机制生成文本。GSEM 利用图的邻接特性加强相邻节点的生成概率,有效避免了生成过程中实体信息的丢失,提高了生成文本与知识图谱

所反映事实的一致性。

$$d_t^{\text{att}} = \tanh(\mathbf{W} \cdot [\mathbf{d}_t \oplus \mathbf{q}_t]) \quad (13)$$

式(13)利用记忆上下文向量 q_t 输入指针生成网络与解码器中的 LSTM 隐藏状态 d_t ,协同指导解码。其中, \oplus 表示两向量的拼接操作。

$$\mathbf{P}_{\text{gen}}(y_t | y_{<t}) = \text{Softmax}(\mathbf{W} \cdot \mathbf{d}_t^{\text{att}} + b_{\text{att}}) \quad (14)$$

式(14)根据解码上下文向量 d_t^{att} 计算得到词汇概率分布 $\mathbf{P}_{\text{gen}}(y_t)$ 。

$$a_{t,z} \propto \exp(\mathbf{d}_t^{\text{att}} \cdot \mathbf{W} \cdot \mathbf{V}_z) \quad (15)$$

$$\mathbf{P}_{\text{copy}}(n_t) = \sum_{y_t \leftarrow z} a_{t,z} \quad (16)$$

式(15)、式(16)将所有实体词作为复制词汇词表,解码上下文向量 d_t^{att} 与样本中出现的实体表示 V_z ,计算注意力系数,并投影注意力权重系数到复制词表,成为复制概率。

$$\beta = \text{Softmax}(\mathbf{W} \cdot [\mathbf{d}_t \oplus \mathbf{q}_t] + b_\beta) \quad (17)$$

$$\mathbf{m}_t = \lambda_{\text{gsem}} \mathbf{P}_{t-1}^{\text{gsem}} + (1 - \lambda_{\text{gsem}}) \mathbf{m}_{t-1}, \mathbf{m}_0 = 0 \quad (18)$$

$$\mathbf{P}_{\text{gsem}}(n_t) = \beta \cdot \mathbf{P}_{\text{copy}}(n_t) + (1 - \beta) \cdot \mathbf{A} \cdot \mathbf{m}_t \quad (19)$$

式(17)根据解码隐藏状态 d_t 和记忆上下文向量 q_t 计算权重,用于调节图结构增强的程度。式(18)记录以往生成词汇的概率。每一个时间步都通过上一个时间步的 GSEM 增强的复制概率更新实体记忆 m ,其中 λ_{gsem} 为超参数。相邻的实体节点下一次被选择的可能性更高,因此利用邻接矩阵 A 与以往概率记忆 m 相乘对相邻接点的概率进行增强。

$$\theta = \text{Sigmoid}(\mathbf{W} \cdot \mathbf{d}_t + b_d) \quad (20)$$

$$\mathbf{P}(y_t) = \theta \cdot \mathbf{P}_{\text{gsem}}(n_t) + (1 - \theta) \cdot \mathbf{P}_{\text{gen}}(y_t | y_{<t}) \quad (21)$$

式(21)采用条件复制将生成概率和复制概率相结合。将生成概率和图结构增强的复制概率进行融合,得到最后的概率分布。

3.4 双层重构机制

双层重构机制是所提模型的第三阶段,如图2中的上半部分所示。准确描述知识图谱的生成文本中一定蕴含了丰富的知识特征,而这些知识以不同形式的方式隐藏在转译文本中。受自编码器的启发,本文采用不同角度的重构以抽取输入信息的不同特征,促进解码器准确全面地获取编码器中蕴含的本质特征,进一步提高生成文本对信息描述的可靠性。如图2所示,本文采用两种重构,分别将生成文本重构为静态内容规划和知识图谱,确保生成文本中内容描述顺序与静态内容规划基本一致,并且保证各实体之间的关系与给定知识图谱相同。值得注意的是,本文所论述的重构机制仅在训练阶段辅助解码器获取信息,而不在测试阶段使用。

3.4.1 重构1:静态内容规划重构

如图2所示,重构1根据生成文本重构静态内容规划,即将生成文本过程中解码器的隐藏状态利用循环神经网络解码还原静态规划,监督生成解码器,抽取静态内容规划中的潜在特征。将指针生成网络最后的隐藏状态作为重构解码器的初始隐藏状态。重构1的具体过程如式(22)一式(24)所示:

$$a_i^{\text{recl}} \propto \exp(\mathbf{d}_t \cdot \mathbf{h}_i^{\text{recl}}) \quad (22)$$

$$\mathbf{q}_t^{\text{recl}} = \sum_i^T a_i^{\text{recl}} \cdot \mathbf{d}_i \quad (23)$$

$$\mathbf{P}^{\text{recl}}(SP = \text{trik}) = \text{Softmax}(\mathbf{W} \cdot \mathbf{q}_t^{\text{recl}} + b) \quad (24)$$

式(22)将重构1 LSTM 的隐藏状态 $\mathbf{h}_i^{\text{recl}}$ 作为出发点,观察生成文本解码器所有时间步的隐藏状态 d_t ,其中 t 为重构

LSTM 中的时间步, $i \in [1, T]$ 表示生成解码器 LSTM 中的所有时间步。式(23)通过注意力机制计算文本上下文向量 $\mathbf{q}_i^{\text{recl}}$ 。式(24)计算选择节点的概率。因此,生成文本恢复至静态内容规划的重构的损失函数可以定义为:

$$L_{\text{recl}} = -\frac{1}{|SP|} \sum_{i=1}^{|SP|} (\log \mathbf{P}^{\text{recl}}(SP = \text{tri}_k)) \quad (25)$$

其中, $|SP|$ 表示静态内容规划的序列长度。损失函数旨在根据生成的描述文本提取出先前的静态规划,促使文本尽可能以静态内容规划的顺序生成。

3.4.2 重构2:知识图谱关系预测重构

如图2所示,本文将生成文本重构为知识图谱的问题转换为根据解码器解码过程中实体的隐藏状态编码预测实体之间的关系。通过重构2促使生成文本中实体之间的关系仍然与原始输入知识图谱一致,即保证了知识图谱与生成文本的事实一致性。重构2的具体过程如式(26)一式(28)所示,通过参考文本定位实体位置来获取实体对应的隐藏表示,根据三元组内的实体顺序标记为 $\mathbf{h}_{\text{sub}}, \mathbf{h}_{\text{obj}}$ 。

$$\tilde{\mathbf{h}} = \text{Sigmoid}(\mathbf{W} \cdot (\mathbf{h}_{\text{sub}} \oplus \mathbf{h}_{\text{obj}})) \quad (26)$$

$$\mathbf{P}(r_z | \mathbf{h}_{\text{sub}}, \mathbf{h}_{\text{obj}}) \propto \exp(\tilde{\mathbf{h}} \cdot \mathbf{W} \cdot \mathbf{r}_z) \quad (27)$$

式(26)对 \mathbf{h}_{sub} 和 \mathbf{h}_{obj} 进行拼接变换后得到实体间的关系隐藏表示 $\tilde{\mathbf{h}}$ 。式(27)采用注意力机制,根据实体间的关系隐藏表示 $\tilde{\mathbf{h}}$ 来观察真实关系表示 \mathbf{r}_z , 所得注意力系数即为预测两实体之间关系为 z 的概率。

$$L_{\text{rec2}} = -\frac{1}{K} \sum_{i=1}^K (\log \mathbf{P}(r_z | \mathbf{h}_{\text{r}, \text{sub}}, \mathbf{h}_{\text{r}, \text{obj}})) \quad (28)$$

其中, K 表示样本给出的三元组个数。融入知识图谱重构后,模型能够进一步匹配实体和关系之间的语义信息,提高生成文本的事实一致性。

3.5 文本转译损失函数

本文提出的知识图谱转译模型通过静态内容规划、动态记忆解码和双层重构机制这3个阶段,实现了图结构到文本的转译。其中,静态内容规划、动态记忆解码和双层重构均有各自的目标函数。

$$L_{\text{sp}} = -\sum_{i=1}^{|SP|} \log \mathbf{P}(SP_i = \text{tri}_i^z | \mathbf{d}_i, \mathbf{V}_{SP_{i-1}}), \text{tri}_i^z \in \text{Gold SP} \quad (29)$$

式(29)表示生成静态内容规划的负对数似然损失函数,促使生成静态内容规划尽可能与样本中给出的参考序列一致。

$$L_{\text{lm}} = -\frac{1}{T} \sum_{i=1}^T (\log \mathbf{P}(\hat{y}_i)), \hat{y}_i \in \text{Reference} \quad (30)$$

式(30)表示生成文本的负对数似然损失函数,促使生成文本尽可能与样本中给出的参考文本一致。此外,为了进一步提高转译文本效果,本文还引入了有监督复制和覆盖机制。

$$L_{\text{supervised_copy}} = -\frac{1}{T} \sum_{i=1}^T (\|\theta - \hat{\theta}\|_2) \quad (31)$$

如式(31)所示,有监督复制旨在根据参考文本中的实体位置,指导生成文本在每一个时间步选择性生成词表词汇或复制实体词。其中 $\hat{\theta}$ 用于判断参考文本中的词汇属于生成词表还是复制词表。若词汇属于生成词表,则 $\hat{\theta} = 0$, 若词汇属于复制词表,则 $\hat{\theta} = 1$ 。

$$L_{\text{coverage}} = -\frac{1}{N} (\sum_{i=1}^T \mathbf{P}_{\text{gsem}} - 1) \quad (32)$$

如式(32)所示,为了使生成文本尽可能全面反映输入三元组中的所有实体,模型引入覆盖机制。覆盖机制促使样本中所有的实体词生成且仅生成一次。其中 $\sum_{i=1}^T \mathbf{P}_{\text{gsem}}$ 为生成过程中所有时间步各实体复制概率的总和, N 为实体数, T 为最大时间步。值得一提的是,有监督复制与覆盖机制仅在训练阶段辅助解码器优化,而在测试阶段对生成文本没有影响。

最终,如式(33)所示,本文提出的知识图谱至文本转译模型损失函数由三模块中的静态规划损失、生成文本损失、双层重构损失以及有监督复制损失和覆盖损失共同组成,其中 $\lambda_1 \sim \lambda_6$ 均为超参数。

$$L_{\text{TOTAL}} = \lambda_1 \cdot L_{\text{sp}} + \lambda_2 \cdot L_{\text{lm}} + \lambda_3 \cdot L_{\text{recl}} + \lambda_4 \cdot L_{\text{rec2}} + \lambda_5 \cdot L_{\text{supervised_copy}} + \lambda_6 \cdot L_{\text{coverage}} \quad (33)$$

4 实验分析

4.1 数据集与实验设置

本文针对 WebNLG 数据集进行实验,数据集中的知识图谱以三元组集合的形式作为输入,每一个知识图谱都给出了对应描述该知识图谱的文本。数据集中包含 9674 个三元组集合与 25298 条描述文本,其中知识图谱中三元组数最大为 7,具体各三元组数目的样本数量分布如图4所示。数据集对多个类进行了描述,包括飞机场、宇航员、建筑、城市、漫画人物、食物、纪念碑、运动队伍、大学、著作。实验在相同的域内进行训练和测试,并采用与文献[15]相同的 WebNLG 版本,该版本还给出了与生成文本对应的三元组描述顺序,便于检验中间阶段内容规划生成效果。

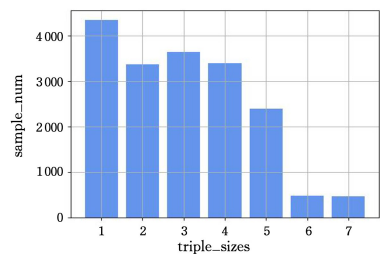


图4 不同三元组数的样本数目

Fig. 4 Sample_number of different triple_sizes

本文中实验的详细参数设置如表1所列。本文使用 word2vec 对词向量进行预训练,实验词典大小为 5301,词嵌入维度为 256,隐藏层向量为 256。

表1 实验参数设置

Table 1 Experimental parameter setting

参数	取值
优化器	Adam
Learning_rate	0.0005
Hidden_dim	256
Embedding_dim	256
Max_dec_step	59
Vocab_size	5301
Batch_size	20
Decoder_layer	3
λ_{gsem}	0.5
λ_{1-6}	1/6

本文使用 BLEU, METEOR, ROUGE, CHRF++, CTER 作为评价指标^[42]。BLEU 是一种对机器翻译的结果进行自动评估的方法,通过计算共现词频率来衡量两句话的一致程度,强调句子的准确性和流畅性。ROUGE 基于召回率评价转译文本的质量,即查看参考译句中的词组出现在转移文本中的比例。METEOR 考虑了同义词匹配,基于语料库计算转译文本准确率和召回率。CHRF++ 在字符级对生成文本质量进行评估,侧重字符级别的准确率与召回率。CTER 通过计算生成文本与参考文本之间的字符级编辑距离进行评估,该值越低说明转译文本与参考文本越接近,侧重生成文本

和参考文本之间的相似度。

4.2 所提方法自身讨论

4.2.1 训练效果

本文在解码器模块加入了记忆转移机制、覆盖机制、有监督复制机制与双层重构。图 5 分别给出了训练过程中生成文本的准确率与静态内容规划的准确率的变化情况,以及生成文本、静态内容规划、覆盖机制、有监督复制机制、双层重构机制的损失变化。通过图 5 可以看出,各个机制的损失都在不断下降,生成文本与静态内容规划的准确率最终都达到了 0.8 以上。

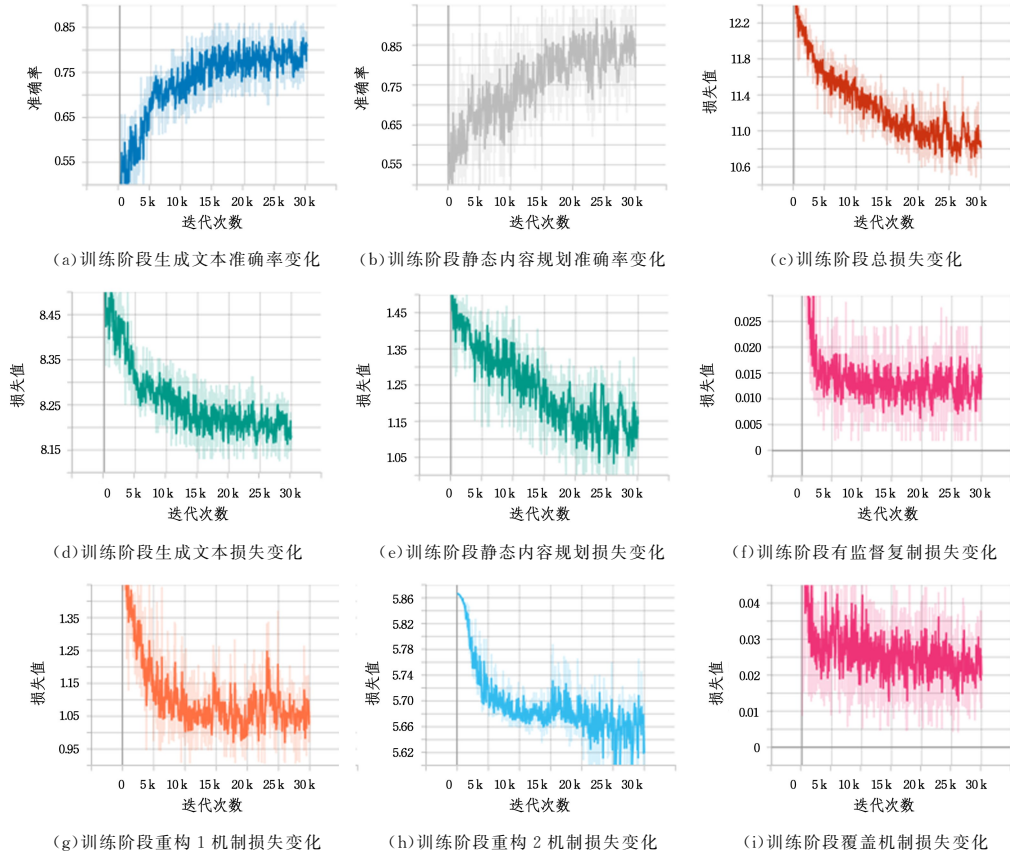


图 5 训练阶段精度变化与损失变化

Fig. 5 Accuracy and loss changes during training

4.2.2 静态内容规划效果

静态内容规划为模型指明了三元组的描述顺序。针对静态内容模块,本文通过 BLEU-2, CO, Accuracy 这 3 个指标对静态内容规划效果进行了评价。BLEU-2 旨在评判生成三元组序列中前后三元组顺序是否与参考内容规划顺序一致,考虑前后片段的语义相关性。内容顺序(Content Ordering, CO)运用归一化的 Damerau-Levenshtein 编辑距离评判生成内容规划与参考内容规划之间的差距,CO 值越趋向于 1,表示两文本越相近^[3]。准确率(Accuracy)通过比较对应位置的三元组是否与参考顺序一致来评判生成的内容规划效果。

图 6 给出了不同三元组数目下的静态内容规划效果。三元组数目越大,内容规划器的难度就更大。当三元组数目为 2 时,BLEU 达到了 0.8,CO 接近于 1,这说明模型基本能够准确识别三元组的先后描述顺序。当三元组数目增加至 7,

所生成的内容规划准确率为 0.4,BLEU 与 CO 仍然能够接近 0.5,这说明所提模型虽然生成规划与参考规划的对应位三元组不同,但仍能够在多个三元组中分析得到各三元组之间的逻辑相关性且与参考内容规划相近。




图 6 不同三元组数目的静态内容规划效果对比

Fig. 6 Comparison of static content plan results of different numbers of triples

4.2.3 消融实验分析

本文以静态内容规划与基于循环神经网络的序列到序列网络结合的生成模型(LSTM-Seq2Seq)作为基线,为了明确各机制的实质作用,采用累加的形式进行消融实验,依次向Seq2Seq网络中加入记忆转移机制(+Memory Shift)、重构1机制(+Rec1)、覆盖机制(+Coverage)、有监督复制(+Supervised_copy)、重构2机制(+Rec2)。所提模型消融性实验的具体结果如表2所列,表2中Ablation列缩进表示为在已有组合基础上的叠加机制。LSTM-Seq2Seq加入记忆转移机制后,BLEU和METEOR指标提高了6.39%和4.57%,CTER下降了0.2,这说明模型可以捕捉语句与语句之间的重点中心词的转移,增强了语义之间的关联性,转译文本与参考文本更加接近。在此基础上加入重构1机制,重构1机制由生成文本隐藏状态提取静态内容规划的机制,强化了模型从静态内容规划

中抽取符合描述文本序列顺序特征的能力,因此BLEU和METEOR指标提高了0.73%和3.69%。在记忆转移机制与重构1机制之上加入覆盖机制,BLEU提高了2.73%,METEOR指标提高了0.53%,Rouge-L指标提高了1.53%,这说明生成文本能够提及更多知识图谱中包含的内容。在记忆转移机制与重构1机制之上加入有监督复制机制,CTER指标降低了1.13%,这说明有监督复制机制能够指导模型在恰当的时间步复制实体信息。在记忆转移机制与重构1机制之上同时加入覆盖机制与有监督复制机制,BLEU和METEOR分别提高了1.21%和0.9%。在覆盖机制和有监督复制机制基础上,加入由生成文本隐藏状态恢复为知识图谱的重构2机制后,BLEU略微下降,而METEOR提高了2.47%,CHRF++指标提高了4.83%,可见重构2机制进一步匹配了实体和关系之间的语义信息,提高了生成文本的事实一致性。

表2 消融实验结果

Table 2 Ablation results

Ablation	BLEU/%	METEOR/%	ROUGE-1/%	ROUGE-L/%	CHRF++/%	CTER↓
LSTM-Seq2Seq	52.48	37.16	64.31	61.07	58.16	0.6249
+Memory Shift	58.87	41.73	66.59	66.99	68.47	0.4247
+Rec1	59.60	45.42	71.99	72.85	73.49	0.4197
+Coverage	62.33	45.95	73.82	74.38	74.35	0.4500
+Supervised_copy	64.27	43.47	67.63	67.61	70.05	0.4084
+Coverage+Supervised_copy	65.48	44.37	69.22	69.13	73.86	0.4057
+Rec2	65.07	46.84	74.07	74.84	78.69	0.3940

4.3 对比实验

本文选择以下方法进行实验对比。

(1)GMP^[21]利用自注意力机制对三元组中的字符进行层级编码,将图结构信息融入到三元组和节点表示¹⁾。

(2)CGW-LW^[19]运用GAT从局部和全局角度对知识图谱的节点编码并用Transformer生成文本²⁾。

(3)KGPT^[14]引入外部知识库并运用GPT预训练模型,生成描述文本³⁾。

(4)T5/BART^[24]没有显式编码图结构,直接运用现有的预训练模型解码⁴⁾。

对比实验中选取各个实验的角度各有不同,GMP对知识图谱进行线性化编码,CGW-LW采用图神经网络编码,KGPT引入外部知识库,T5和BART采用大规模预训练模型生成文本,旨在从不同角度与所提模型进行对比,凸显所提模型

的优越性。WebNLG数据集非常适合短文本的生成。所提模型中静态内容规划对应于图谱内容选择与计划模型;记忆转移和解码模块分别对应于图谱重要内容定位和生成模型。模型仅在Seen域上进行比较,即测试集和训练集中数据类别相同。生成结果比较的具体指标结果如表3所列,所提模型在BLEU和METEOR等多个指标上均优于其他模型。其中BLEU提高了至少1.49%,CHRF++提高了至少0.47%,证明记忆机制结合从内容规划中捕获的符合上下文语境的“中心节点”,提高了生成文本的语义连贯性;CTER低于除T5_{small}之外的所有模型,证明静态内容规划机制能够通过合理的内容规划降低生成文本与参考文本之间的差异,且仅高于大规模预训练模型T5_{small}不到0.01。并且所提模型参数量明显小于大规模预训练模型,说明所提模型的效率更高,其各个机制能够有效强化描述文本的生成,以弥补参数量上的差距。

表3 对比实验生成结果

Table 3 Generation performance comparisons of different methods

Model	BLEU/%	METEOR/%	ROUGE-1/%	ROUGE-L/%	CHRF++/%	CTER↓	Parameters
GMP	55.84	40.78	66.79	66.07	66.99	0.4746	8.59×10 ⁶
CGW-LW	61.82	44.03	68.10	65.45	75.31	0.4462	10.50×10 ⁶
KGPT	63.21	46.70	71.73	74.58	74.98	0.3948	177.32×10 ⁶
T5 _{small}	63.55	45.69	72.32	74.33	78.22	0.3856	60.49×10 ⁶
Bart _{base}	63.38	44.68	71.99	73.74	76.30	0.3944	139.42×10 ⁶
Ours	65.07	46.84	74.07	74.84	78.69	0.3940	17.47×10 ⁶

内容规划结果的具体指标结果如表4所列,指标与4.2节中讨论自身方法内容规划的指标一致。对其他模型的转译

文本首先按逗号、句号或and、whose等词汇划分为短句,并通过最小编辑距离与各输入三元组匹配,去除重复的三元组序

¹⁾ <https://github.com/Nicoleqwert/RDF-to-Text>

²⁾ <https://github.com/UKPLab/kg2text>

³⁾ <https://github.com/wenhuchen/KGPT>

⁴⁾ <https://github.com/UKPLab/plms-graph2text>

号以生成对应的内容规划。可见,所提模型在内容规划上的效果均优于其他模型,BLEU-2 提高了至少 4.49%,CO 提高了至少 3.58%,说明静态内容规划机制能够产生更加合理准确的内容规划,为模型转译文本指明描述的对象和描述顺序。

表 4 对比实验内容规划结果

Table 4 Content plan performance comparisons of different methods

Model	BLEU	Accuracy	CO
GMP	34.24	38.27	0.678 5
CGW-LW	60.65	64.59	0.681 7
KGPT	55.59	55.37	0.564 9
T5 _{small}	48.61	49.05	0.486 4
Bart _{base}	48.06	49.30	0.500 5
Ours	65.14	59.57	0.717 5


与 CGW-LW 模型表现相比,所提模型的 Accuracy 降低了 5.02%,而 BLEU 提高了 4.49%,CO 提高了 3.58%,说明

虽然所提模型的生成规划与参考规划存在位置偏差,但其生成规划的前后关联与参考规划更加一致,进一步提高了生成文本的语义连贯性。

4.4 生成效果分析

根据表 3 所列的结果,选取对比方法中两个表现最佳的模型所转译的文本与本文模型转译文本进行比较分析,具体结果如图 7 所示。本文列举了两个例子,生成文本下不同颜色区域对应不同的三元组。可以发现,在示例 2 中,语义上 deceased 应与 deathplace,deathdate 更加相近,而 T5 转译文本首先描述 deceased,然后描述 was selected by NASA,语句间的逻辑薄弱;KGPT 转译文本描述 deathplace 与 deathdate 之间插入了对 birthdate 的描述,句间语义相关性较弱。而所提模型生成文本由于静态内容规划机制(见图 2),使得转译前后短句之间的相关性更强,描述逻辑更加合理。

示例 1:



参考文本

Operated by the Port Authority of New York and New Jersey, Atlantic City International Airport is 23 metres above sea level. It has the runway name 4/22 and the runway length, 3048.0.

T5模型转译文本

The Port Authority of New York and New Jersey is the operating organisation of Atlantic City International Airport which is 23 metres above sea level. The runway name is 4/22 and has a length of 3048.0.

KGPT模型转译文本


Port Authority of New York and New Jersey is the operating organisation of Atlantic City International Airport which has the runway name 4/22 and has a runway length of 3048.0. It is 23.0 metres above sea level.

本文模型转译文本

Atlantic city international airport is operated by Port Authority of New York and New Jersey and is 23.0 metres above sea level. Atlantic city international airport runway name is 4/22 and it has is 3048.0.

(a) 示例 1 转译文本效果展示

示例 2:



参考文本

Elliot see, a US national, was born on 1927 07 23. Elliot see was a test pilot and began working for NASA in 1962. Elliot see died on 1966 02 28 in st.louis.

T5模型转译文本

Elliot see is deceased and was selected by NASA in 1962. American Elliot see was born on 1927 07 23 and died in st.louis.

KGPT模型转译文本

Elliot See was selected by NASA in 1962 and became a test pilot. He died in st.louis. He was born on July 23rd 1927 and died on February 28th 1966.

本文模型转译文本

Elliot see was born in 1927 07 23 in united states. Elliot see was test pilot and was selected by NASA in 1962. Elliot see died in 1966 02 28 in st.louis.

(b) 示例 2 转译文本效果展示

图 7 转译文本效果对比分析

Fig. 7 Generation comparison analysis

示例 1 中的生成文本对三元组的内容规划顺序与参考文本的内容规划一致,示例 2 中,仅 birthdate 与 nationality 顺序对调,生成语句仍然通顺且逻辑完整。由于静态内容规划与

记忆机制相结合,如图 3 所示,模型可以根据已生成文本信息对静态内容规划进行微调,去捕获与当前关注三元组最相关的信息。对比示例 2,在三元组数目为 7 的知识图谱转译

文本上,其他模型容易遗漏部分三元组信息,而所提模型通过式(32)所示的覆盖机制可以描述更多的三元组。而从图7(a)中可以观察到,与 KGPT, T5 模型相比,本文模型转译文本并未清楚表述出“the runway length is 3048”,分析其原因是本文模型的参数量少于 KGPT 和 T5,模型解码器能力仍然有待提高。因此,在未来我们将尝试使用大规模预训练语言模型改进解码器。

结束语 本文提出了基于内容规划机制与双层重构的知识图谱生成文本模型,通过静态内容规划、动态内容规划和双层重构机制三阶段完成知识图谱向文本的转译。静态内容规划提前规划出对应知识的描述顺序,将结构化数据向文本进行线性转化,补足结构化数据和非结构化文本之间的差距;动态内容规划将实体记忆机制与生成过程相结合,追踪生成文本与静态内容规划的关系,把握句间描述重点的转移;利用双层重构机制,根据生成文本重构静态规划并还原知识图谱,从多个角度引导解码器捕捉知识图谱中的本质特征。实验结果表明,本文模型与现有同类的转译模型相比,内容规划更加准确,生成文本语句间的逻辑合理且关联性更强。在实验中发现,所提模型泛化能力较弱,在训练集未出现类别的知识数据上,转译文本的效果并不理想。因此,未来将尝试使用大规模预训练语言模型,在保持现有转译文本效果的同时,进一步提高模型对未见过的知识的理解能力。

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] LIU Q, LI Y, DUAN H, et al. Knowledge Graph Construction Techniques[J]. Journal of Computer Research and Development, 2016, 53(3): 582-600.
- [3] WYLOT M, HAUSWIRTH M, CUDRÉ-MAUROUX P, et al. RDF data storage and query processing schemes: A survey[J]. ACM Computing Surveys(CSUR), 2018, 51(4): 1-36.
- [4] PUDUPULLY R, DONG L, LAPATA M. Data-to-text generation with content selection and planning[C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2019: 6908-6915.
- [5] ZHANG X B, GONG H G, YANG F, et al. Chinese sentence-level lip reading based on end-to-end model[J]. Journal of Software, 2020, 31(6): 1747-1760.
- [6] XU F, LUO J, WANG M, et al. Speech-driven end-to-end language discrimination toward chinese dialects[J]. ACM Transactions on Asian and Low-Resource Language Processing(TALLIP), 2020, 19(5): 1-24.
- [7] GARDENT C, SHIMORINA A, NARAYAN S, et al. The WebNLG challenge: Generating text from RDF data[C]//Proceedings of the 10th International Conference on Natural Language Generation, 2017: 124-133.
- [8] WISEMAN S J, SHIEBER S M, RUSH A S M. Challenges in Data-to-Document Generation[C]//Proceedings of the Conference on Empirical Methods in Natural Language Processing(EMNLP2017). Association for Computational Linguistics, 2017.
- [9] KUKICH K. Design of a knowledge-based report generator [C]//21st Annual Meeting of the Association for Computational Linguistics, 1983: 145-150.
- [10] BAO J, TANG D, DUAN N, et al. Table-to-text: Describing table region with natural language[C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2018.
- [11] BANARESCU L, BONIAL C, CAI S, et al. Abstract meaning representation for sembanking[C]//Proceedings of the 7th Linguistic Annotation Workshop and Interoperability with Discourse, 2013: 178-186.
- [12] DISTIAWAN B, QI J, ZHANG R, et al. GTR-LSTM: A triple encoder for sentence generation from RDF data[C]//Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics(Volume 1: Long Papers), 2018: 1627-1637.
- [13] LI W, PENG R, WANG Y, et al. Knowledge graph based natural language generation with adapted pointer-generator networks [J]. Neurocomputing, 2020, 382(1): 174-187.
- [14] CHEN W, SU Y, YAN X, et al. KGPT: Knowledge-Grounded Pre-Training for Data-to-Text Generation[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing(EMNLP), 2020: 8635-8648.
- [15] GAO H, WU L, HU P, et al. RDF-to-text generation with graph-augmented structural neural encoders[C]//Proceedings of the Twenty-Ninth International Conference on International Joint Conferences on Artificial Intelligence, 2021: 3030-3036.
- [16] XU B B, CEN K T, HUANG J J, et al. A survey on Graph Convolution Neural Network [J]. Chinese Journal of Computers, 2020, 43(5): 755-780.
- [17] GUO Z, ZHANG Y, TENG Z, et al. Densely connected graph convolutional networks for graph-to-sequence learning [J]. Transactions of the Association for Computational Linguistics, 2019, 7(1): 297-312.
- [18] BECK D, HAFFARI G, COHN T. Graph-to-sequence learning using Gated Graph Neural Networks[C]//Annual Meeting of the Association of Computational Linguistics 2018. Association for Computational Linguistics(ACL), 2018: 273-283.
- [19] KONCEL-KEDZIORSKI R, BEKAL D, LUAN Y, et al. Text Generation from Knowledge Graphs with Graph Transformers [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: 2284-2293.
- [20] SHI Y, LUO Z, ZHU P, et al. G2T: Generating Fluent Descriptions for Knowledge Graph[C]//Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval, 2020: 1861-1864.
- [21] GAO H, WU L, HU P, et al. RDF-to-text generation with graph-augmented structural neural encoders[C]//Proceedings of the Twenty-Ninth International Conference on International Joint Conferences on Artificial Intelligence, 2021: 3030-3036.
- [22] RIBEIRO L F R, ZHANG Y, GARDENT C, et al. Modeling global and local node contexts for text generation from knowledge graphs[J]. Transactions of the Association for Computational Linguistics, 2020, 8(1): 589-604.

- [23] XU F, DAN Y, YAN K, et al. Low-Resource Language Discrimination toward Chinese Dialects with Transfer Learning and Data Augmentation[J]. Transactions on Asian and Low-Resource Language Information Processing, 2021, 21(2): 1-21.
- [24] RIBEIRO L F R, SCHMITT M, SCHÜTZE H, et al. Investigating Pretrained Language Models for Graph-to-Text Generation [C]// Proceedings of the 3rd Workshop on Natural Language Processing for Conversational AI. 2021; 211-227.
- [25] KALE M, RASTOGI A. Text-to-Text Pre-Training for Data-to-Text Tasks[C]// Proceedings of the 13th International Conference on Natural Language Generation. 2020; 97-102.
- [26] LI J, TANG T, ZHAO W X, et al. Few-shot Knowledge Graph-to-Text Generation with Pretrained Language Models [C] // Findings of the Association for Computational Linguistics: ACL-IJCNLP 2021. 2021; 1558-1568.
- [27] KURITA K, MICHEL P, NEUBIG G. Weight Poisoning Attacks on Pretrained Models[C]// Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. 2020; 2793-2806.
- [28] MIAO N, SONG Y, ZHOU H, et al. Do you have the right scissors? Tailoring Pre-trained Language Models via Monte-Carlo Methods[C]// Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. 2020; 3436-3441.
- [29] FERREIRA T C, VAN DER LEE C, VAN MILTENBURG E, et al. Neural data-to-text generation: A comparison between pipeline and end-to-end architectures[C]// 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. Association for Computational Linguistics, 2019; 552-562.
- [30] CHU X M, ZHU Q M, ZHOU G D. Discourse Primary-Secondary Relationships in Natural Language Processing[J]. Chinese Journal of Computers, 2017, 40(4): 842-860.
- [31] MORYOSSEF A, GOLDBERG Y, DAGAN I. Step-by-Step: Separating Planning from Realization in Neural Data-to-Text Generation [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; 2267-2277.
- [32] ZHAO C, WALKER M, CHATURVEDI S. Bridging the structural gap between encoding and decoding for data-to-text generation[C]// Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. 2020; 2481-2491.
- [33] PUDUPPULLY R, DONG L, LAPATA M. Data-to-text generation with content selection and planning[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2019; 6908-6915.
- [34] PUDUPPULLY R, LAPATA M. Data-to-text Generation with Macro Planning[J]. Transactions of the Association for Computational Linguistics, 2021, 9(1): 510-527.
- [35] SHAO Z, HUANG M, WEN J, et al. Long and Diverse Text Generation with Planning-based Hierarchical Variational Model [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; 3257-3268.
- [36] SU Y, VANDYKE D, WANG S, et al. Plan-then-Generate: Controlled Data-to-Text Generation via Planning[C]// Findings of the Association for Computational Linguistics: EMNLP 2021. 2021; 895-909.
- [37] LEWIS M, LIU Y, GOYAL N, et al. BART: Denoising Sequence-to-Sequence Pre-training for Natural Language Generation, Translation, and Comprehension[C]// Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. 2020; 7871-7880.
- [38] CHEN K, LI F, HU B, et al. Neural Data-to-Text Generation with Dynamic Content Planning[J]. arxiv:2004. 07426, 2020.
- [39] ISO H, UEHARA Y, ISHIGAKI T, et al. Learning to select, track, and generate for data-to-text[J]. Journal of Natural Language Processing, 2020, 27(3): 599-626.
- [40] PUDUPPULLY R, DONG L, LAPATA M. Data-to-text Generation with Entity Modeling[C]// Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. 2019; 2023-2035.
- [41] SHEN X, CHANG E, SU H, et al. Neural Data-to-Text Generation via Jointly Learning the Segmentation and Correspondence [C]// Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. 2020; 7155-7165.
- [42] GEHRMANN S, ADEWUMI T, AGGARWAL K, et al. The GEM Benchmark: Natural Language Generation, its Evaluation and Metrics[C]// 1st Workshop on Natural Language Generation, Evaluation, and Metrics 2021. Association for Computational Linguistics, 2021; 96-120.



MA Tinghuai, born in 1974, Ph.D, professor. His main research interests include social network privacy protection, big datamining, text emotion computing, etc.



RONG Huan, born in 1990, Ph.D, lecturer. His main research interests include social media mining, content security on social network, knowledge engineering, etc.

(责任编辑:喻黎)