

文章编号: 1003-0077 (2011) 00-0000-00

基于知识拷贝机制的生成式对话模型*

李少博, 孙承杰, 徐振, 刘秉权, 季振洲, 王明江

(哈尔滨工业大学计算机科学与技术学院, 黑龙江省 哈尔滨市 150001)

摘要: 基于“编码-解码”结构的生成式对话模型所生成的回复多样性差、信息量少, 这很大程度上阻碍了对话的进一步扩展和深入。而知识图谱作为一种高度结构化的知识, 能够为对话提供相关知识以及话题转移关系, 有利于对话的延伸。因此, 本文提出了一种基于知识拷贝机制的生成式对话模型, 首先使用基于知识图谱的映射机制对对话内容进行处理, 随后使用知识拷贝机制直接将知识图谱中的知识引入到生成的回复中, 并使用注意力机制选择知识图谱中的信息来指导回复的生成。在“2019 语言与智能技术竞赛”中的“知识驱动对话”数据集上, 相较竞赛举办方提供的生成式基线模型, 本文所提出模型生成的回复在准确性指标和多样性指标上分别有 10.47%、4.6% 的提升。

关键词: 生成式对话模型; 知识图谱; 端到端

中图分类号: TP391

文献标识码: A

Knowledge Copying Mechanism for Dialog Generation

LI Shaobo, SUN Chengjie, XU Zhen, LIU Bingquan, JI Zhenzhou, WANG Mingjiang

(School of Computer Science and Technology, Harbin Institute of Technology, Harbin,

Heilongjiang 150001, China)

Abstract: The generative end-to-end dialog models suffer from generating monotonous and non-informative responses, which impedes the development of dialog. As a highly structured knowledge source, knowledge graph can provide relevant information and topics transfer relationships that is conducive to the continuation of the dialog. Therefore, a generative dialog model based on knowledge graph is proposed. First, a knowledge graph based mapping mechanism is used to process the dialog, then a copying mechanism is used to directly introduce the utterances contained in the knowledge graph into the generated responses and the information contained in knowledge graph is also used to guide the generation of responses by attention mechanism. On the "Knowledge-Driven Dialogue" dataset presented in the "2019 Language and Intelligent Competition", the proposed model outperformed the baseline model provided by competition organizer by 10.47% in accuracy and 4.6% in diversity.

Key words: generative dialog model; knowledge graph; end-to-end

1 引言

作为自然语言处理领域内的主要研究问题, 自动对话系统近年来受到了越来越多的关注。特别是“编码-解码”结构在机器翻译任务上取得了重大进展之后^[1], 基于“编码-解码”结构的生成式对话模型也成为了一个热点研究方向。一方面, 基于“编码-解码”结构的对话模型可以在大规模的对话语料上以端到端的方式训练。另一方面, 根据当前对话自动生成对应回复的模型为自动对话系统的构建提供了新的范式。

由于对话语料中的词频符合长尾分布^[2], 且模型的优化目标属于经验风险最小化, 基于“编码-解码”结构的对话模型更趋于产生信息量低的回复。为了解决这个问题, 很多研究者从目标函数^[3]、解码方法^[4]、主题信息^[5]等方面进行了深入的探索。同时, 也有研究者注

* **收稿日期:** **定稿日期:**

基金项目: 国家自然科学基金 (61572151, 61602131, 61672192, 61672555); 深圳市知识创新计划-基础研究项目 (JCYJ20170808110410773)

作者简介: 李少博 (1993—), 男, 博士生, 自然语言处理; 孙承杰 (1980—), 男, 副教授, 自然语言处理; 徐振 (1989—), 男, 博士, 自然语言处理; 刘秉权 (1970—), 男, 副教授, 自然语言处理; 季振洲 (1965—), 男, 教授, 并行处理技术; 王明江 (1968—), 男, 教授, 语音处理技术。

意到，知识在对话过程中也起着十分重要的作用，知识不仅有助于对话的理解，分析对话之间的内在联系^[6-7]，还能够为回复生成提供更丰富的信息，增加对话的广度和深度。而知识图谱^[8-9]作为一种高度结构化的知识，能够以三元组（实体，关系，属性）的形式提供高质量的知识。如何在端到端的模型中有效的利用知识图谱，将其融入到“编码-解码”结构中，正吸引着越来越多研究者的目光。

为此，本文提出了一种基于知识拷贝机制的生成式对话模型。首先，本文使用提出基于知识图谱的映射机制对对话内容进行处理，利用知识图谱将对话中出现的实体和属性映射为特殊的标识符，从一定程度上克服词频分布不均导致的所生成回复信息量低的问题。随后，模型使用知识拷贝机制，以拷贝的形式直接将知识图谱中的词汇拷贝到回复中。最后，模型利用注意力机制从知识图谱中选择最有效信息来进一步指导回复的生成。实验表明，本文提出的模型所生成的回复在准确性和多样性上均有不错的表现。

本文接下来的内容安排如下：在第 2 部分中，对端到端的生成式对话模型以及如何在其中融入知识的相关工作进行了简要介绍；在第 3 部分中，详细介绍了本文提出的模型，所使用数据集以及使用映射机制对对话内容进行处理的方式；在第 4 部分中，对本文提出的模型进行了实验对比和分析；在第 5 部分中对本文的工作进行了总结。

2 相关工作

由于互联网社交平台中（例如新浪微博）积累了大量的对话资源，数据驱动的生成式对话模型受到了越来越多的关注。Ritter 和 Vinyals 等发现对话系统中的“消息-回复”关系可按照机器翻译中“编码-解码”过程来建模，通过对编码后的消息序列进行解码来生成回复序列，构建了端到端的生成式对话系统^[10-12]。早期的研究工作的重点主要集中在对话的语义表示、语义关系计算以及上下文建模上^[13-15]，没有考虑外部知识在对话过程中的作用。

在[16]中，作者首先做出了如下假设：对话参与者给出的回复不仅仅依赖于对话历史，同时也依赖于参与者了解的与对话有关的相关知识。作者使用 Reddit 论坛中的对话和维基百科页面构建了对话以及相关知识语料库，分别使用循环神经网络（Recurrent Neural Network, RNN）和卷积神经网络（Convolutional Neural Networks, CNN）对对话和相关知识进行编码，利用这两部分编码信息来生成回复序列。

在[17]中，自然语言形式的相关知识被表示为词袋（Bag of Words, BOW）的形式，使用类似于 Memory Network^[18]的方式将其转换为知识编码向量，随后将该向量附加到 RNN 解码器的初始状态中。同时，该文为模型的训练定义了多个任务，在训练模型时，按照预先定义的方式随机选择一个任务进行训练。在解码时，使用增加了回复长度和互信息特征的集束搜索（Beam Search）来生成最终的回复。

Wu 等人在利用相关知识的生成回复的同时，提出一种知识选择机制^[19]。在训练过程中，根据对话历史和训练集中的真实回复来选择最相关的知识，保证训练过程中所选知识的准确性；在生成回复的过程中，模型仅使用对话历史来选择知识。为了处理模型在训练与生成时所选知识的之间的差异，模型使用了多种损失函数进行优化。

3 基于知识拷贝机制的生成式对话模型

3.1 模型结构

本文提出的模型是一种基于“编码-解码”结构改进而来的端到端模型，其中包含对话历史编码模块、知识编码模块、知识拷贝模块和注意力解码模块 4 个部分。模型生成回复序列中每个词的过程如图 1 所示。

模型的输入包括对话历史和与对话相关的知识图谱两部分。首先使用对话历史编码模块和知识编码模块分别将对话历史和知识图谱中的知识条目转换为向量形式的表示，随后使用知识拷贝模块和注意力解码模块将其解码为回复词序列。

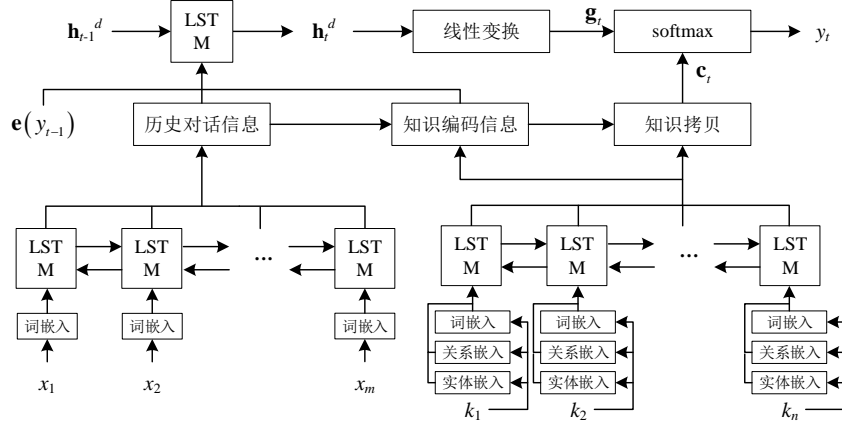


图1 模型的生成过程

3.1.1 对话历史编码模块

$X = \{x_1, x_2, \dots, x_m\}$ 表示由对话历史依次拼接起来形成词序列，通过词嵌入层将其转换为词向量序列 $\{e(x_1), e(x_2), \dots, e(x_m)\}$ 后，使用双向 LSTM (Long Short-Term Memory) [20] 将词向量序列编码为隐状态序列 $\{h_1^x, h_2^x, \dots, h_m^x\}$ 。

3.1.2 知识编码模块

在对三元组形式的知识图谱中的知识条目进行编码过程中，编码的主体是三元组中的属性部分。首先将相关知识图谱三元组中的所有属性拼接成为一个词序列 $K = \{k_1, k_2, \dots, k_n\}$ ，随后将其转换为词向量序列 $\{e^k(k_1), e^k(k_2), \dots, e^k(k_n)\}$ 。为了保留每个词在三元组中的关系和实体信息，在序列 K 中的每个词的词向量上添加了额外的关系和实体编码。 K 中第 j 个词的词向量 $e^k(k_j)$ 计算方式如公式 (1) 所示。

$$e^k(k_j) = e(k_j) + e(r_j) + e(E_j) \quad (1)$$

其中 r_j 表示 k_j 在知识图谱中所对应的属性， E_j 表示 k_j 对应的实体，由于知识图谱中关系的种类是有限的，故 $e(r_j)$ 的取值为在词嵌入层中预先定义的若干个额外的嵌入向量。同样的，与对话内容相关的实体数量也是有限的，则 $e(E_j)$ 的取值为在词嵌入层中预先定义的若干个额外的嵌入向量。最后同样使用双向 LSTM 将 $\{e^k(k_1), e^k(k_2), \dots, e^k(k_n)\}$ 编码为隐状态序列 $\{h_1^k, h_2^k, \dots, h_n^k\}$ 。

通过上述编码方式，知识被编码为向量形式的表示，其中包含的信息一方面被知识拷贝模块使用，来判断是否对序列 K 中词进行拷贝，另一方面被注意力解码模块用于指导回复的生成。

3.1.3 知识拷贝模块

拷贝机制 [21] 的主要思想是在生成回复序列中的每一个词时，模型可以从一个额外的候选词汇集中选出一个词作当前生成的结果。这样一来，可以通过构建一个数量较小、包含信息量较为丰富的候选词汇集合，来帮助模型生成质量更高的回复。同时在候选词汇集中也可以包含词表中未出现过的词汇，增强模型的泛化能力。

本文使用知识图谱中属性所包含的词作为候选词汇集合，拷贝方式参考了 CopyNet [21] 中的拷贝机制，与其不同的是，CopyNet 中的拷贝机制是从对话历史中拷贝，对话历史是完整的自然语言对话，拷贝时可以利用的词上下文关系。而知识拷贝是从知识图谱三元组中属性拼接成的词序列 K 中拷贝，词的前后相关性较弱，故在知识编码模块中保留了关系信

息和实体信息以便知识拷贝模块利用。

知识拷贝的具体过程如下：在对回复序列中的第 t 个词进行解码时，不仅计算词表中每个词的生成概率，同时计算序列 K 中每个词被拷贝的概率，若拷贝概率大于生成的概率，则将拷贝概率最大的词直接作为回复中第 t 个词 y_t 。

K 中第 j 个词 k_j 的拷贝概率使用公式 (2) 计算。其中 \mathbf{h}_t^d 为注意力解码模块在解码第 t 个词时的状态向量。

$$\psi_t(k_j) = \tanh(\mathbf{h}_j^k \mathbf{W}^C) \mathbf{h}_t^d \quad (2)$$

在知识拷贝过程中，模型需要记录已经被拷贝的词的相关信息，这一信息称为选择性输入 (Selective Read)，这一信息有助于模型综合利用被拷贝词本身包含的信息以及词的位置信息^[21]，选择性输入使用公式 (3) 计算。

$$\mathbf{s}_t = \sum_{j:k_j=y_{t-1}}^n \psi_{t-1}(k_j) \mathbf{h}_j^k \quad (3)$$

3.1.4 注意力解码模块

本文使用 LSTM 作为解码模块的核心，将其他模块输出的信息作为输入，解码出回复词序列 $Y = \{y_1, y_2, \dots, y_T\}$ 。在解码回复词序列中第 t 个词 y_t 时，注意力解码模块输入的信息包括对话历史信息 \mathbf{c}_t^x 、知识编码信息 \mathbf{c}_t^k 、选择性输入 \mathbf{s}_t 、回复词序列中的第 $t-1$ 个词的词向量 $\mathbf{e}(y_{t-1})$ 以及解码第 $t-1$ 词时解码模块中 LSTM 的状态向量 \mathbf{h}_{t-1}^d 。接下分别来介绍 \mathbf{c}_t^x 和 \mathbf{c}_t^k 的计算过程以及解码过程。

首先，对话历史信息 \mathbf{c}_t^x 是使用注意力机制对对话历史的隐状态序列 $\{\mathbf{h}_1^x, \mathbf{h}_2^x, \dots, \mathbf{h}_m^x\}$ 进行加权求和得到，其过程如公式 (4) 所示。

$$\begin{aligned} e_i^x &= \mathbf{h}_i^x \mathbf{W}^X \mathbf{h}_{t-1}^d \\ \{a_1^x, a_2^x, \dots, a_m^x\} &= \text{softmax}(\{e_1^x, e_2^x, \dots, e_m^x\}) \\ \mathbf{c}_t^x &= \sum_{i=1}^m a_i^x \mathbf{h}_i^x \end{aligned} \quad (4)$$

随后，同样使用注意力机制，从已经编码为 $\{\mathbf{h}_1^k, \mathbf{h}_2^k, \dots, \mathbf{h}_n^k\}$ 的知识中选择出与当前回复最相关的知识组成知识编码信息 \mathbf{c}_t^k ，对知识中包含的相关信息进一步的利用，例如在知识图谱中存在“口碑很好”的这一属性，那么这一信息经过编码后可以帮助生成“很不错哦”、“推荐给你”这类积极性回复的生成。 \mathbf{c}_t^k 的计算过程如公式 (5) 所示。

$$\begin{aligned} e_j^k &= \mathbf{h}_j^k \mathbf{W}^{KD} \mathbf{h}_{t-1}^d + \mathbf{h}_j^k \mathbf{W}^{KX} \mathbf{c}_t^x \\ \{a_1^k, a_2^k, \dots, a_n^k\} &= \text{softmax}(\{e_1^k, e_2^k, \dots, e_n^k\}) \\ \hat{a}_j^k &= \begin{cases} a_j^k & a_j^k > \frac{p}{n} \\ 0 & a_j^k \leq \frac{p}{n} \end{cases} \\ \mathbf{c}_t^k &= \sum_{j=1}^n \hat{a}_j^k \mathbf{h}_j^k \end{aligned} \quad (5)$$

与对话历史中的注意力机制有所不同的是，知识编码信息中的注意力权重使用对话历史信息 \mathbf{c}_t^x 和解码状态向量 \mathbf{h}_{t-1}^d 共同计算，旨在同时利用对话历史信息和当前解码状态一起来选择序列 K 中最相关的知识。同时我们考虑到，在生成回复时， K 中的知识并不一定都是与回复相关的，因此在计算注意力权重时引入了截断机制。在公式 (5) 中，若权重 a_j^k 小于

一定的阈值，则直接将这部分信息截断，截断后的权重表示为 \hat{a}_j^k ，其中 p 为预先定义的参数。通过引入截断机制，使模型具备了对不相关的知识编码信息进行排除的能力。

最后， \mathbf{c}_t^x 、 \mathbf{c}_t^k 、 \mathbf{s}_t 和 $\mathbf{e}(y_{t-1})$ 这四个部分被拼接为一个完整的向量后送入解码模块的LSTM中，对状态向量 \mathbf{h}_{t-1}^d 进行更新，如公式（6）所示。随后使用公式（7）进行解码。

$$\mathbf{h}_t^d = \text{LSTM}(\mathbf{h}_{t-1}^d, [\mathbf{c}_t^x; \mathbf{c}_t^k; \mathbf{s}_t; \mathbf{e}(y_{t-1})]) \quad (6)$$

$$\begin{aligned} \mathbf{g}_t &= \mathbf{W}^O \mathbf{h}_t^d \\ \mathbf{c}_t &= \{\psi_t(k_1), \psi_t(k_2), \dots, \psi_t(k_n)\} \\ \mathbf{o}_t &= \text{softmax}([\mathbf{g}_t; \mathbf{c}_t]) \end{aligned} \quad (7)$$

其中 \mathbf{g}_t 为长度与词表大小相同的向量，表示词表中每个词的生成概率， \mathbf{c}_t 为长度为 n 的向量，表示序列 K 中每个词的拷贝概率。将两个向量拼接后，使用softmax函数进行归一化处理。若 \mathbf{o}_t 中的值最大的元素存在于与 \mathbf{g}_t 对应的部分中，则将词表中对应的词作为 y_t ，若存在于 \mathbf{c}_t 所对应的部分中，则将 K 中相应的词作为 y_t 。若在序列 K 中出现了词表中相同的词，则将相同的词对应的拷贝概率与生成概率相加后再进行比较。

为了对解码模块输入的各部分信息的有效性进行验证，本文共构建了4个不同的模型，如表1所示，其中最后一个模型MCTA为本文最终使用的模型。

表1 构建的模型信息

模型	说明	注意力解码状态更新以及参数
M	仅使用映射机制	$\mathbf{h}_t^d = \text{LSTM}(\mathbf{h}_{t-1}^d, [\mathbf{c}_t^x; \mathbf{e}(y_{t-1})])$
MC	在模型M的基础上增加知识拷贝机制	$\mathbf{h}_t^d = \text{LSTM}(\mathbf{h}_{t-1}^d, [\mathbf{c}_t^x; \mathbf{s}_t; \mathbf{e}(y_{t-1})])$
MCA	在模型MC的基础上增加知识编码信息	$\mathbf{h}_t^d = \text{LSTM}(\mathbf{h}_{t-1}^d, [\mathbf{c}_t^x; \mathbf{c}_t^k; \mathbf{s}_t; \mathbf{e}(y_{t-1})])$, $p = 0$
MCTA	在模型MCA的基础上对知识编码信息进行截断	$\mathbf{h}_t^d = \text{LSTM}(\mathbf{h}_{t-1}^d, [\mathbf{c}_t^x; \hat{\mathbf{c}}_t^k; \mathbf{s}_t; \mathbf{e}(y_{t-1})])$, $p = 1$

3.2 数据集

3.2.1 数据格式

本文使用了[19]中提供的数据集，该数据集在“2019语言与智能技术竞赛”中的“知识驱动对话”任务中使用¹。数据集中的样本包括了“对话内容”、“对话话题及其关联”和“与话题相关的知识图谱”三个部分，并包含了分词信息。其中“对话内容”中包括了多轮对话，对话的话题指定为两个，话题和以及话题之间的关系在“对话话题及其关联”部分中给出，最后给出了与两个话题相关的知识图谱。数据集中的样本形式如表2所示。

表2 数据集中的样本形式

对话内容	对话话题及其关联
1. 你喜欢看美国电影吗？	珍珠海, 芳华
2. 很喜欢，你这么问，你也喜欢吗？	(珍珠海, 类型, 剧情)
3. 我也喜欢，那你看过Heather McComb主演的珍珠海吗？	(芳华, 类型, 剧情)
4. 是2008年上映的那一部吗？	与话题相关的知识图谱
5. 对，2008年3月2日上映的。	(珍珠海, 主演, Heather McComb)
6. 挺好看的。	(珍珠海, 国家, 美国)
7. 还有一部电影叫芳华，而且还是你喜欢的战争类型的影片哦！	(芳华, 时光网 短评, 芳华 已逝, 但求无悔 ...)
8. 这个我听过，但还没有去看。	...
9. 网评说芳华已逝，但求无悔，看完之后真的让人感触很深。	(芳华, 是否上映, 已上映)
10. 有时间一定去观赏一下。	...

¹ <http://lic2019.ccf.org.cn/talk>

3.2.2 基于知识图谱的映射机制

对话中经常会使用许多语义相近的词汇，例如“北京市”和“上海市”均表示地理位置，“狼牙山五壮士”与“上甘岭”均表示电影的名称。这些词汇有着相近的语义但却又互不相同，模型按照经验风险最小化的方式训练后，会趋向于选择语义相近的词汇中出现频率较高的词，这使得生成得回复中难以包含准确的信息，例如若在训练数据中“北京市”出现次数高于“上海市”的出现次数，那么模型在生成表示地理位置信息的词汇时，会更倾向于生成“北京市”，进而造成生成回复中包含错误的、与相关知识不相符的信息。

针对这一问题，本文提出使用基于知识图谱的映射机制对对话内容进行处理，其主要思想是利用相关知识，将对话内容中语义相近的词汇序列映射为相同的特殊的标识符，对这一部分内容进行统一的表示后输入到模型中，在模型生成回复序列后再将其中包含的特殊标识符还原为相关知识中对应的内容。

为了设计针对本文所使用数据集的映射机制，本文首先对数据集中的词频进行了统计，如表3所示。

表3 数据集中的词频情况

词在对话内容出现的频率	数量(占比)	包含在知识图谱中的数量
出现1次	23020(46.85%)	15729
出现2-10次	20238(41.19%)	16985
出现11-100次	4889(9.95%)	4702
出现101-1000次	777(1.58%)	754
大于1000次	205(0.41%)	203
总计	49129	38373(78%)

从表3中可以看出，对话内容所形成的词表中共包含了49129个词，其中46.85%的词仅仅出现过1次，88.04%的词出现次数小于10次，这一部分低频词汇的学习和生成对于模型来说是十分困难的。同时，如表中第3列所示，知识图谱词表和对话内容词表有很大一部分重合，故使用基于知识图谱的映射机制对该数据集进行处理是十分必要的，处理后的结果如表4所示。

在该数据集上，映射机制处理规则如下：若对话内容中的词序列与知识图谱中的某一属性完全匹配，则将其替换成特殊标识符。特殊标识符的两端为字符“@”。由于该数据集中每一轮对话仅包含两个话题，故使用“@TA@”、“@TB@”分别表示话题名称。在其余的特殊标识符中，字母“A”表示用于第一个话题相关的属性，字母“B”表示第二个话题相关的属性，字母后面的部分表示所替换内容在知识图谱中对应的关系。

表4 映射后的对话内容

1. 你 喜 欢 看 @A 国家@ @B 领域@ 吗？
2. 很 喜 欢 ， 你 这 么 问 ， 你 也 喜 欢 吗 ？
3. 我 也 喜 欢 ， 那 你 看 过 @A 主 演@ 主 演 的 @TA@ 吗 ？
4. 是 @A 上 映 年 份@ 上 映 的 那 一 部 吗 ？
5. 对 ， @A 上 映 时 间@ 上 映 的 。 挺 好 看 的 。
6. 挺 好 看 的 。
7. 还 有 一 部 @B 领 域@ 叫 @TB@ ， 而 且 还 是 你 喜 欢 的 @B 类 型@ 类 型 的 影 片 哦 ！
8. 这 个 我 听 过 ， 但 还 没 有 去 看 。
9. 网 评 说 @TB@ 已 逝 ， 但 求 无 悔 ， 看 完 之 后 真 的 让 人 感 触 很 深 。
10. 有 时 间 一 定 去 观 赏 一 下 。

经映射机制处理后的词频情况如表5所示。可以发现，经映射机制处理后，词表的大小减少了47.19%，对话数据得到了有效的简化。同时，出现次数小于10次的低频词也有很大幅度的降低，词频不均现象也得到了改善，这能够进一步帮助模型对数据进行学习。

表 5 映射机制处理后的词频情况

词出现的频率	数量
出现 1 次	13142
出现 2-10 次	9190
出现 11-100 次	2732
出现 101-1000 次	666
大于 1000 次	213
总计	25943

4 实验分析

本文所使用的数据集的详细信息如表 6 所示。

表 6 数据集的详细信息

数据集	训练集	开发集	测试集
样本数量	19858	2000	5000
问答对数量	179800	18108	5000

在训练集中，多轮对话被拆分为对话历史与回复形成的问答对，将每一个问答对作为一个单独的训练样本。测试集中的多轮对话则直接拼接成对话历史用作模型输入。模型使用贪心的方式进行解码。模型中主要参数设置如表 7 所示。

表 7 模型中主要参数设置

参数	数值
词向量维数	300
编码器中 LSTM 隐藏层维数	512
编码器中 LSTM 堆叠层数	1
学习速率	0.001

4.1 自动评价指标对比

在实验中，本文使用准确性指标字符级别的 F1^[22]、词级别 BLEU-1 和 BLEU-2^[23]以及多样性指标 DISTINCT-1 和 DISTINCT-2^[3]对模型进行评价。评价结果如表 8 所示，评价指标是基于测试集数据，使用“2019 语言与智能技术竞赛”提供的线上评价系统计算得到的。Baseline-R 和 Baseline-G 分别表示竞赛举办方提供的检索式基线模型和生成式基线模型²，这两个模型是使用与[19]中相似的方法构建的。同时，为了进一步对映射机制进行对比和验证，分别使用原始的对话数据和经映射机制处理后的对话数据训练了[21]中所提出的拷贝模型，表示为 CopyNet 和 CopyNet-M。

表 8 模型结果的评价指标对比

模型名称	F1 (%)	BLEU-1/BLEU-2	DISTINCT-1/ DISTINCT-2
CopyNet	25.21	0.272/0.117	0.02/0.053
Baseline-R	31.72	0.291/0.156	0.118/0.373
Baseline-G	32.65	0.3/0.168	0.062/0.128
CopyNet-M	36.94	0.320/0.1893	0.088/0.191
M	36.08	0.304/0.180	0.103/0.217
MC	41.08	0.361/0.226	0.119/0.278
MCA	42.80	0.378/0.243	0.111/0.288
MCTA	43.12	0.376/0.244	0.108/0.259

由表 8 中可以看出，首先，使用映射机制的生成式模型 M 以及 CopyNet-M 相较未使用映射机制的生成式模型 Baseline-G 和 CopyNet 的结果有了大幅度提升。在使用了基于知识图谱的映射机制后，对话内容中存在大量的低频词汇被统一为特殊标识符，而特殊标识符在对话内容中的出现频率是一定高于替换前的原始词汇的，在生成回复时，相对高频的特殊标识符生成的风险要低于低频词汇，这保证了特殊标识符在回复中的出现频率，在将其还原成知识图谱中对应的内容后，也就提高了生成式模型回复的多样性。同时，在模型训练时，特

²<https://github.com/baidu/knowledge-driven-dialogue>

殊标识符相较于低频词汇有更多的机会参与到模型训练中,有利于模型充分掌握特殊标识符表示的语义,降低了数据的复杂度和模型对其的学习难度。

与模型 M 相比,添加了知识拷贝机制的模型 MC 的结果又有了进一步的提升。通过对结果进一步统计分析,发现约 6.3% (3456/54739) 的词是通过知识拷贝机制直接拷贝到回复中的,这说明回复的质量提升主要归功于知识拷贝机制。同时,被拷贝的词中还包括 184 个不包含在词表中的词,说明拷贝机制对不在词表中的词汇也有一定处理能力。

从表 8 中还可以看出,增加了知识编码信息的模型 MCA 和 MCTA 在指标上又有了进一步的提升,这说明编码后相关知识的语义与回复的语义之间存在着较强的相关关系,在解码时选择合适的知识,能够帮助回复的生成。此外,引入截断机制的 MCTA 与 MCA 模型在评价指标上各有优势,相较 MCA, MCTA 在字符集别的 F1 上有所提升,而词级别的 BLEU-1 和 BLEU-2 则有所下降,经过分析,这可能是由于生成回复与真实回复之间的分词存在差异造成的,例如在回复中包含词序列“看”“电影”而在真实回复中的包含的词是“看电影”,导致了 F1 与 BLEU 之间的差异。同时由于词频不均的原因,准确性指标和多样性指标之间存在矛盾,随着生成回复准确性的提升,多样性也略有下降。

4.2 具体实例分析

表 9 模型生成结果对比

实例 1	
对话历史	怎么会有这么可爱又帅的人。谁啊。刘芮麟啊, o 型血, 65kg。你好变态啊还看人家这些信息。我哪有。你就有。我是看了他主演的电影才知道的啦! 可惜这部电影的评分不高, 只有 5.1。这么低啊, 哪部电影这么不好看?
Baseline-G	龙拳小子, 这部电影是 <num>年前上映的, 很精彩的。
MCTA	龙拳小子, <u>2016年8月2日</u> 上映的。
真实回复	叫龙拳小子, 网上评论说好看, 孩子很喜欢。
实例 2	
对话历史	你喜欢看美国电影吗? 很喜欢, 你这么问, 你也喜欢吗? 我也喜欢, 那你看过 Heather McComb 主演的珍珠海吗? 是 2008 年上映的那一部吗? 对, 2008 年 3 月 2 日上映的。挺好看的。还有一部电影叫芳华, 而且还是你喜欢的战争类型的影片哦! 这个我听过, 但还没有去看。
Baseline-G	影片是 <num>年上映的, 网评说是一部很差, 剧情也很精彩。
MCTA	是剧情类型的, 网评说芳华已逝但求无悔, 我觉得你会喜欢的。
真实回复	网评说芳华已逝, 但求无悔, 看完之后真的让人感触很深。
实例 3	
对话历史	你喜欢欧美电影吗? 喜欢, 很有视觉冲击。
Baseline-G	狩猎, 这部电影, 你看过吗?
MCTA	狩猎, 这部电影口碑很不错, 你可以去看看。
真实回复	电影狩猎口碑不错, 推荐你看下。
实例 4	
对话历史	你看过大丈夫吗? 你说的那部电视剧吗? 不是啊, 我说的电影你说的彭胖子导演的那个吗? 是啊, 就是彭浩翔导演的那个。看过啊, 这么好的影片, 当年还获台湾电影金马奖提名呐。
Baseline-G	是啊, 他还导演了一部电影, 还获得了 <num>年第<num>届华语电影传媒大奖的最佳男配角。
MCTA	是啊, 他还获得过金马奖最佳原创剧本呢。
真实回复	大丈夫是一部中国香港电影。
实例 5	
对话历史	喜欢那个类型的导演呢? 喜剧类的吧。哦, 是吗? 那喜欢编感动类型的导演吴念真你可以了解下, 他有部电影《多桑》, 可以让你边笑边哭。好的, 有时间看一下。还有啊, 我最近看了一部剧情片, 也很好看, 推荐给你吧好呀, 告诉我哪部电影
Baseline-G	他凭借作品 <unk>
MCTA	他还获得过 2011 年第 24 届东京国际电影节主竞赛单元的最佳男演员呢。
真实回复	他是摩羯座的。还凭借无法触碰获得了 2011 年第 24 届东京国际电影节主竞赛单元最佳男演员奖呢。

表 9 中列举了模型 MCTA 的生成结果、模型 Baseline-G 的生成结果以及真实回复的一些具体实例。

在实例 1 中, 对于“上映日期”这类能够与知识图谱类完全匹配词汇, 映射机制能准确的将其引入; 在实例 2 中, 对于“时光网 短评”这类无法完全匹配的内容, 知识拷贝机制也能够很好的处理, 将其无缝融入到回复中。在实例 3 中, 知识图谱中存在“狩猎, 口碑, 口碑 不错”这一信息, 其以知识编码的方式添加到解码过程中, 模型能够将其在回复中体现出来。在实例 5 中, 本文提出的模型利用映射与拷贝机制, 生成的回复中包含了大量的低频事实性词汇, 相较模型 Baseline-G, 回复的质量有很大的提高。

同时可以发现, 在实例 2 中, 由于端到端模型中并没有使用特殊的机制来保证回复中语义的一致性, Baseline-G 模型生成的结果出现了前后矛盾的情况。同样, 在实例 4 中, Baseline-G 模型生成了与事实不相符的信息。对于本文提出的模型来说, 回复中的事实性内容能够通过映射和拷贝机制直接由知识图谱中引入, 在一定程度上保证了信息的准确性和一致性, 提高了生成式对话系统的实用性。

5 结论

本文提出了一种基于知识拷贝机制的生成式对话模型。首先, 模型使用基于知识图谱的映射机制对对话内容进行处理, 一定程度上简化了对话内容, 克服了词频长尾分布对模型造成的影响。其次, 通过知识拷贝机制, 模型能够将适合的词汇拷贝到回复中。最后, 模型使用了注意力机制选择最相关的知识并将其引入到回复中, 对回复的生成进行指导。

实验表明, 本文提出的模型能够提高端到端的对话模型所生成回复的准确性和多样性, 使得所生成的回复更加恰当和实用。

参考文献

- [1] Sutskever, Ilya, Oriol Vinyals, Quoc V. Le. Sequence to Sequence Learning with Neural Networks[C]//Proceedings of Advances in Neural Information Processing Systems. New York, USA: Curran Associates, 2014: 3104-3112.
- [2] Powers, David MW. Applications and Explanations of Zipf's law[C]//Proceedings of the Joint Conferences on New Methods in Language Processing and Computational Natural Language Learning, Copenhagen, Denmark: Association for Computational Linguistics, 1998: 151-160.
- [3] Li, J., Galley, M., Brockett, C., et al. A Diversity-Promoting Objective Function for Neural Conversation Models[C]//Proceedings of Human Language Technology Conference of the North American Chapter of the Association of Computational Linguistics (NAACL-HLT), Denver, USA, Association of Computational Linguistics, 2016:110-119.
- [4] G Shao, L., Gouws, S., Britz, D., et al. Generating Long and Diverse Responses with Neural Conversation Models. 31 Jul 2017, <https://arxiv.org/pdf/1701.03185.pdf>
- [5] Wang, D., Jovic, N., Brockett, C., et al. Steering Output Style and Topic in Neural Response Generation[C]//Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing (EMNLP), Copenhagen, Denmark: Association for Computational Linguistics, 2017: 2140-2150.
- [6] Zhou, H., Young, T., Huang, M., et al. Commonsense Knowledge Aware Conversation Generation with Graph Attention[C]//Proceedings of International Joint Conference on Artificial Intelligence, Stockholm, Sweden: International Joint Conferences on Artificial Intelligence, 2018: 4623-4629.
- [7] Markov á I., Linell, P., Grossen, M., et al. Dialogue in focus groups: Exploring socially shared knowledge[M]. London: Equinox Publishing, 2007: 256.
- [8] Fabian, M. S., Kasneci Gjergji, W. E. I. K. U. M. Gerhard. Yago: A Core of Semantic Knowledge Unifying Wordnet and Wikipedia[C]//Proceedings of International World Wide Web Conference (WWW), New York, USA: ACM 2007: 697-706.
- [9] 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.
- [10] Ritter, A., Cherry, C., Dolan, W. B. Data-driven Response Generation in Social Media[C]//Proceedings of the 2011 Conference on Empirical Methods on Natural Language Processing (EMNLP), Copenhagen, Denmark: Association for Computational Linguistics, 2011: 583-593.
- [11] Vinyals, Oriol, Quoc Le. A Neural Conversational Model. 22 Jul 2015, <https://arxiv.org/pdf/1506.05869>
- [12] Cho, K., Gulcehre, B.V.M.C., Bahdanau, et al. Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP), Copenhagen, Denmark: Association for Computational Linguistics, 2014: 1724-1734.
- [13] Shang, L., Lu, Z., Li, H. Neural Responding Machine for Short-text Conversation[C]//Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference

- on Natural Language Processing (ACL-IJCNLP), Copenhagen, Denmark: Association for Computational Linguistics, 2015: 1577-1586.
- [14] Sordoni, A., Galley, M., Auli, M, et al. A Neural Network Approach to Context Sensitive Generation of Conversational Responses[C]//Proceedings of the 2015 Conference of the North American Chapter of the Association for Computational Linguistics, Copenhagen, Denmark: Association for Computational Linguistics, 2015: 196-205.
- [15] Serban, I. V., Sordoni, A., Lowe, R, et al. A Hierarchical Latent Variable Encoder-Decoder Model for Generating Dialogues[C]//Proceedings of 31nd AAAI Conference on Artificial Intelligence (AAAI), New Orleans, USA: AAAI press, 2017: 3295-3301.
- [16] Vougiouklis, P., Hare, J., Simperl, E., A Neural Network Approach for Knowledge-Driven Response Generation[C]//Proceedings of 26th International Conference on Computational Linguistics (COLING), Vancouver, Canada, Association for Computational Linguistics, 2016: 3370-3380.
- [17] Ghazvininejad, M., Brockett, C., Chang, M.W., et al. A Knowledge-Grounded Neural Conversation Model[C]//Proceedings of 32nd AAAI Conference on Artificial Intelligence (AAAI), New Orleans, USA: AAAI press, 2018: 5110-5117.
- [18] Weston, J., Chopra, S. Bordes. A Memory Networks. 29 Nov 2015, <https://arxiv.org/pdf/1410.3916.pdf>
- [19] Wu, W., Guo, Z., Zhou, X., et al. Proactive Human-Machine Conversation with Explicit Conversation Goal, [C]//Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics (ACL), Copenhagen, Denmark: Association for Computational Linguistics, 2019.
- [20] Schuster M, Paliwal K K, Bidirectional Recurrent Neural Networks[J]. IEEE Transactions on Signal Processing, 1997, 45(11): 2673-2681.
- [21] Gu, J., Lu, Z., Li, H. et al. Incorporating Copying Mechanism in Sequence-to-Sequence Learning[C]//Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (ACL), Copenhagen, Denmark: Association for Computational Linguistics, 2016: 1631-1640.
- [22] RADZIWIŁŁ, N., BENTON, M. Evaluating Quality of Chatbots and Intelligent Conversational Agents[J]. Software Quality Professional, 2017,19(3):25.
- [23] Papineni, K., Roukos, S., Ward, T, et al. BLEU: A Method for Automatic Evaluation of Machine Translation[C]//Proceedings of the 40th Annual Meeting on Association for Computational linguistics(ACL), Copenhagen, Denmark: Association for Computational Linguistics, 2002: 311-318.

作者联系方式: 李少博 黑龙江省哈尔滨市西大直街 92 号哈尔滨工业大学 150001 18846932413 (最好手机) shli@insun.hit.edu.cn