

基于对话约束的回复生成研究

管梦雨, 王中卿*, 李寿山, 周国栋

苏州大学计算机科学与技术学院, 苏州, 中国

{20195227007}@stu.suda.edu.cn, {wangzq, lishoushan, gdzhou}@suda.edu.cn

摘要

现有的对话系统中存在着生成“好的”、“我不知道”等无意义的安全回复问题。日常对话中, 对话者通常围绕特定的主题进行讨论且每句话都有明显的情感和意图。因此该文提出了基于对话约束的回复生成模型, 即在Seq2Seq模型的基础上, 结合对对话的主题、情感、意图的识别。该方法对生成回复的主题、情感和意图进行约束, 从而生成具有合理的情感和意图且与对话主题相关的回复。实验证明, 该文提出的方法能有效地提高生成回复的质量。

关键词: 对话生成; 主题识别; 情感识别; 意图识别

Research on Response Generation via Dialogue Constraints

Mengyu Guan, Zhongqing Wang, Shoushan Li, Guodong Zhou

School of Computer Science and Technology, Soochow University, Suzhou, China

{20195227007}@stu.suda.edu.cn, {wangzq, lishoushan, gdzhou}@suda.edu.cn

Abstract

Existing dialogue systems tend to generate meaningless general replies such as "OK" and "I don't know". In daily dialogs, every utterance usually has obvious emotional and intentional tendencies. So this paper proposes a response generation model based on dialogue constraints. Based on the Seq2Seq model, it combines the recognition of utterances' themes, sentiments and intentions. This method constrains the topics, emotions and intentions of the generated responses, generating responses with reasonable sentiment and intention tendencies and related to the topic of the conversation. Experiments show that the method proposed in this paper can effectively improve the quality of generated responses.

Keywords: Dialogue generation, Topic recognition, Sentiment recognition, Act recognition

1 引言

©2020 中国计算语言学大会

根据《Creative Commons Attribution 4.0 International License》许可出版

*通讯作者: wangzq@suda.edu.cn

人机交互(Human Computer Interaction, HCI)作为信息时代人类与计算机之间信息交流的基础技术, 受到学术界和工业界的广泛关注。人机对话(Human-Machine Dialogue)是人机交互技术的核心领域, 旨在最大限度地模仿人与人之间的对话方式, 使得人类能够用更自然的方式与机器进行交流。其应用场景广泛, 具有较高的研究价值和商业价值。构建一个较完备的人机对话系统涉及到NLP技术的很多方面, 比如句法分析 (Fried et al., 2017), 命名实体识别 (Huang et al., 2015)等。本文主要研究多轮对话的回复生成。简而言之就是根据历史对话信息, 自动生成自然合理的回复, 在信息交互的过程中协助用户完成特定的任务。随着端到端框架在机器翻译 (Brown et al., 1993)任务上的良好表现, 研究人员将其迁移应用于对话生成任务中。对话生成可以简化为输入输出的映射问题, 即对对话的输入进行编码和解码从而得到应答。因为对话是有时序的, 可以视为序列, 所以端到端框架下的序列对序列模型(Sequence-to-Sequence, Seq2Seq) (Sutskever et al., 2014; Cho et al., 2014)非常适合对话生成模型。

主题简要地表明了整段对话的内容, 用于理解对话的含义; 情感表明了话语的极性, 用于识别说话者的观点; 意图作为话语的语义标签, 用于描述说话者的动作意图。原则上, 对主题、情感和意图的识别有助于对话内容的理解。表 1给出了一组对话示例, 整段对话是关于“日常生活”的讨论且对话中的每句话都有明确的情感和意图倾向。我们发现, 同一说话者的情感往往是保持不变的; 说话者B作为对话中被动的一方, 意图往往受到对话发起者A的意图的影响。因此本文通过识别对话的主题及每个话语的情感和意图, 对生成的回复进行约束。若我们要生成的是第二轮中说话者B的回复, 我们的方法将生成与对话主题相关、情感倾向于“中性”、意图倾向于“承诺”的回复, 而不是我们通常得到的例如“好的”, “我不知道”等安全回复 (McKay and Piperno, 2014)。

以往的对话生成模型中往往忽视了主题、情感和意图识别的重要性, 因此本文提出了基于对话约束的回复生成模型。具体来说, 在训练阶段, 一方面, 编码器中我们采用单词级别的LSTM网络对对话历史信息中的每个子句进行特征抽取, 得到每个上下文的特征向量。我们将所有的上下文的特征向量整合为一个固定维度的向量作为整组对话的中间语义向量。解码器中我们同样采用单词级别的LSTM网络, 同时考虑中间语义向量和目标回复向量生成回复。另一方面, 我们用上下文的特征向量和生成回复的特征向量来预测整段对话的主题和每个子句的情感和意图。在我们提出的方法中主题预测模型、情感预测模型、意图预测模型和对话生成模型共享了编码和解码阶段的参数。在编码阶段, 通过对主题、情感、意图的识别, 我们可以更好地理解对话中各子句的语义, 生成更高质量的中间向量; 在解码阶段, 在更高质量的中间语义向量的基础上, 对生成回复的情感和意图进行识别, 使得我们生成的回复与对话信息相关且具有合理的情感和意图倾向。在生成阶段, 我们仅需将历史对话信息作为模型输入, 即可生成更高质量的回复。在DailyDialog数据集上的相关实验结果表明, 我们提出的模型明显优于基线系统。

本文的组织结构如下: 第一节介绍论文的研究背景和意义; 第二节主要介绍了对话生成的相关工作; 第三节主要描述了基于对话约束的回复生成模型; 第四节是实验设置的介绍和实验结果分析; 最后, 在第五节中对研究工作进行总结, 同时提出了下一步的研究方向。

A	The sun is beginning to shine. What a lovely summer day! (积极, 陈述) 阳光正好, 多么美好的夏日啊!
B	Yeah, clearly blue sky. But it is a bit too hot for me. (中性, 陈述) 是的, 显然是蓝天。但是对我来说有点热。
A	It's not that hot. It's cooler than yesterday. Let's go swimming!(积极, 指示) 没那么热。今天比昨天凉。我们去游泳吧!
B	If we don't stay too long, we won't get sun-burned. (中性, 承诺) 如果我们不停留太久, 我们不会被晒伤。

表 1. 对话示例

2 相关工作

随着社交网络中大量的聊天语料的积累和硬件计算性能的提升, 通过深度学习 (LeCun

et al., 2015)技术自主提取对话特征, 自动学习生成回复成为可能。Google的Vinyals and Le (2015)首先将机器翻译中的“序列-序列”模型应用于对话生成任务中, 其将回复生成问题视作翻译问题, 编码器与解码器均采用RNN提取特征, 例如长短期记忆网络(Long Short-Term Memory Network, LSTM) (Hochreiter and Schmidhuber, 1997)、门控循环神经单元(Gated Recurrent Unit, GRU)等, 在开放领域和特定领域的预料上进行训练, 均能得到较理想的回复。对话通常是一个持续, 动态的过程, 生成回复是需要考虑当前的对话语境, 即历史信息。Wen et al. (2015)在神经Seq2Seq对话生成模型中, 针对对话任务的依赖历史信息的特征, 改进了LSTM模型, 提出了一种语义控制LSTM应用到对话生成任务中。Sordoni et al. (2015)提出了考虑历史对话信息, 设计了多轮对话的模型, 编码器采用多层前向神经网络(Multilayer Feed-Forward Neural Network)代替循环神经网络模型(Recurrent Neural Network, RNN), 将对话中的历史信息 and 用户对话信息一起进行编码。Serban et al. (2016)则提出采用层级神经网络(Hierarchical Neural Network, HNN)以解决上下文中多个句子的编码问题, 从词级别对句子进行编码, 并用句子编码对上下文进行编码。不同的上下文语境对生成回复内容有着不同的影响, Tao et al. (2018)引入了注意力机制(attention mechanism), 通过计算不同时刻上下文的权重, 决定上下文内容在回复中的表达程度, 取得了更好的效果。在对话生成过程中, 不仅要结合语境还要考虑一定的常识和背景知识, 才能得到更加合理的回复。Kumar et al. (2016)提出了动态记忆网络(Dynamic Memory Network, DMN), 在考虑历史对话信息的基础上, 结合特定的背景和常识信息生成回复。通常, 对话生成中的Seq2Seq模型使用极大似然估计为目标函数, 容易生成符合语法, 但是通用的回复, 例如“我不知道”这样的回复。Li et al. (2016)提出了最大互信息的模型, 通过改变目标函数加强对话消息和回复之间的相关性, 以避免最大似然估计作为目标函数生成安全回复的问题, 生成多样化的回复。Li et al. (2017a)还借鉴生成对抗网络(Generative Adversarial Network, GAN) (Gulrajani et al., 2017)的思想, 提出使用对抗的思想生成回复, 除了训练了对话生成模型, 还训练了一个分辨人与机器回复的鉴别器模型, 用鉴别的结果作为奖励, 使得生成器不断朝更加自然的方向生成回复。Shao et al. (2017)在Seq2Seq模型中对生成端使用注意力机制, 捕捉生成端的信息, 并在模型的解码端使用一种基于分段的随机解码技术。Zhang et al. (2018)提出在Seq2Seq对话模型中使用一个高斯核函数层来指导模型以不同的特殊性生成回复。Xing et al. (2017)在Seq2Seq引入主题模型, 并在编码过程中根据主题类别加入主题词, 使得生成的对话内容中包含更多的语义信息。Xiong et al. (2016)在基于RNN的Seq2Seq模型的基础上, 配合CNN抽取历史对话信息的主题信息特征和主题相关的特征。一些研究者通过加入关键词 (Mou et al., 2016)或使用Beam Search算法 (Vijayakumar et al., 2016)来丰富生成的回复, 增加回复结果的合理性和趣味性。

基于上述工作的启发, 为了解决生成安全回复的问题, 本文提出了基于对话约束的回复生成模型。通过对对话的主题、情感和意图的识别生成更高质量的回复。

3 基于对话约束的回复生成模型

我们的任务旨在自动生成合理自然的对话回复。一组对话由两个对话者之间发起的 $m/2$ 轮对话组成, 可表示为对话序列 $D = \{U_1, U_2, \dots, U_m\}$, 其中 $U_x(x = 1, 2, \dots)$ 称为对话的子句。对话生成模型的目的是在第 $m/2$ 轮时, 根据前面的 $m - 1$ 个子句 $\{U_1, U_2, \dots, U_{m-1}\}$ 计算在此情况下生成句子 U_m 的概率, 即 $P(U_m|U_1, U_2, \dots, U_{m-1})$ 。每个句子 U_m 是可变长的单词序列, 可表示为 $U_m = \{w_{m,1}, w_{m,2}, \dots, w_{m,N_m}\}$ 。其中 $w_{m,n}$ 表示第 m 个句子中的第 n 个单词, N_m 表示 U_m 中的单词个数。通过前 $m-1$ 个子句和当前已经生成的单词来逐字预测下一个词, 直到达到特定的句子长度或者生成结束符, 预测结束, 得到回复 U_m 。 $P(U_m|U_1, U_2, \dots, U_{m-1})$ 可表示为如下公式:

$$P(w_{m,1}, w_{m,2}, \dots, w_{m,n}|U_1, U_2, \dots, U_{m-1}) = \prod_{n=1}^{N_m} P(w_{m,n}|U_1, U_2, \dots, U_{m-1}, w_{<n}) \quad (1)$$

3.1 模型

本文采用的是基于LSTM网络的Seq2Seq模型。该模型包括3个部分:编码器(Encoder)网络、解码器(Decoder)网络和连接Encoder-Decoder的中间语义向量 C 。编码器网络和解码器网络分别对应输入序列和输出序列的两个神经网络, 本实验中编码器和解码器是基于LSTM网络处理输入序列和输出序列的。输入序列通过编码器对其进行编码, 形成一个中间语义向量 C ,

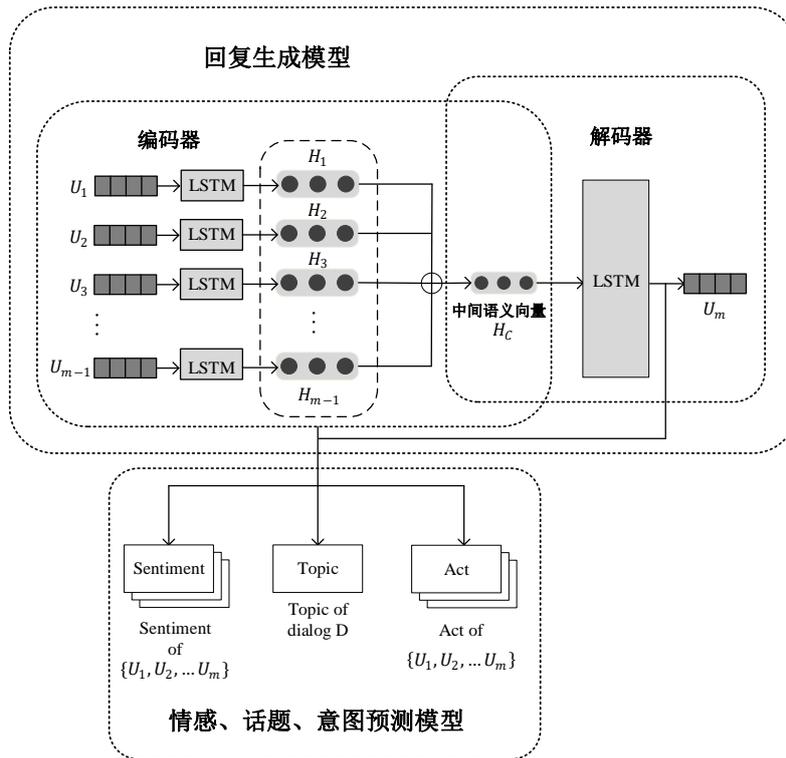


图 1. 模型网络结构图

把这个向量传递给解码器，通过中间语义向量 C 和递归隐藏状态，计算词汇表中每个词的概率分布，生成下一个词，并将其作为下一个时刻的输入，直至遇到结束符标志或达到指定的长度时结束解码。另外我们的模型(JTEA)在模型训练阶段，从编码器和解码器的LSTM网络中学习对话历史对话信息中每个子句和生成回复的特征表示。这些特征向量用于预测每个话语的情感和意图以及整段对话的主题。主题预测、情感预测和意图预测作为对话回复生成的辅助任务，只在模型训练阶段进行，帮助学习编码器和解码器中的共享参数，对生成回复的主题、情感和意图进行约束。模型网络结构图如图 1所示。

3.1.1 编码器

编码器是将输入序列编码成一个中间语义向量 C 。本实验中使每个子句分别经过LSTM神经网络，得到每个子句的特征向量，然后取这些特征向量的平均值，作为中间语义向量 C 。我们可以在两个层次上讨论话语序列：每组对话是由子句序列组成，而每个子句由单词序列组成。基于此，对于给定句子 $U_m = \{w_{m,1}, w_{m,2}, \dots, w_{m,N_m}\}$ ，经过LSTM网络，将最后一层的隐藏层的输出 h_{N_m} 作为该子句的语义向量。本文为历史信息中的每个子句分别构建一个LSTM模型，取所有LSTM模型输出的平均值作为整组对话的中间语义向量 C 。

3.1.2 解码器

解码器是将编码器中生成的中间语义向量 C 再转化成输出序列。在解码阶段，我们会用输出序列 $\{y_1, y_2, \dots, y_{t-1}\}$ 以及中间语义向量 C 来预测下一个输出的单词 y_t ，即

$$y_t = \operatorname{argmax} P(y_t) = \prod_{t=1}^T P(y_t | y_1, y_2, \dots, y_{t-1}, C) \quad (2)$$

通常情况下，会为解码器指定生成文本最大长度和结束字符。在解码过程中，只要符合上述两个条件之一，解码过程就会结束。解码器的输出并不是文本，而是一个向量，这个向量代表着当前这个神经元输出对应词表的概率分布，通常选择概率最高的作为输出，但概率最高的往往是“好的”，“是的”等安全回复。因此，我们引入了主题、情感、意图识别帮助模型更好的理解对话内容，生成与对话主题相关且具有合理情感和意图的回复，增加生成回复的多样性。

3.1.3 主题预测模型

主题预测任务旨在预测整段对话的主题标签，用于约束生成回复的主题。本实验中取各个子句在编码器和解码器中经过LSTM网络得到的特征向量的平均值 \bar{h} 作为主题预测模型的softmax层的输入。给定特征向量 H^t 作为softmax层的输入：

$$P_s^t = \text{softmax}(W_s^t H^t + B_s^t) \quad (3)$$

这里 W_s^t , B_s^t 为模型参数, P_s^t 是意图预测模型的输出, 用于主题分类。

3.1.4 情感预测模型

情感分类任务旨在预测子句的意图标签, 用于约束生成回复的情感倾向。本实验中将每个子句在编码器和解码器中经过LSTM网络得到的特征向量作为情感预测模型的softmax层的输入。给定特征向量 H^s 作为softmax层的输入：

$$P_s^s = \text{softmax}(W_s^s H^s + B_s^s) \quad (4)$$

这里 W_s^s , B_s^s 为模型参数, P_s^s 是情感预测模型的输出, 用于情感分类。

3.1.5 意图预测模型

意图分类任务旨在预测子句的意图标签, 用于约束生成回复的意图倾向。本实验中将每个子句在编码器和解码器中经过LSTM网络得到的特征向量作为意图预测模型的softmax层的输入。给定特征向量 H^a 作为softmax层的输入：

$$P_s^a = \text{softmax}(W_s^a H^a + B_s^a) \quad (5)$$

这里 W_s^a , B_s^a 为模型参数, P_s^a 是意图预测模型的输出, 用于意图分类。

4 实验设置与结果分析

4.1 数据集

本实验使用DailyDialog对话语料 (Li et al., 2017b), 该语料收集于英语学习网站的对话练习。该语料的基本统计信息如表 2所示, 共包含13118个多回合对话, 平均每组对话轮数约为8, 平均每句对话的单词数约为15, 平均每组对话的单词数约为115。该数据集中的对话反映了我们的日常交流方式, 涵盖了我们日常生活的各种话题。该语料中的每句话都标注了情感和意图类别, 这些标注由3名语言专家共同完成, 具有较高的可靠性。其中主题分为10类: 校园生活(School Life)、工作(Work)、健康(Health)、日常生活(Ordinary Life)、人际关系(Relationship)、文化与教育(Culture & Education)、政治(Politics)、态度与情感(Attitude & Emotion)、旅游(Tourism)、金融(Finance); 情感分为7类, 在本实验中我们为了更好的识别情感, 将情感重新分为中性(Neutral)、积极(Positive)、消极(Negative)三类; 意图分为4类: 陈述(Inform)、询问(Question)、指示(Directive)、许诺(Commissive)。

对话总数	13118
平均每组对话轮数	7.9
平均每个子句的单词数	14.6
平均每组对话的单词数	114.7

表 2. DailyDialog基本信息统计

本实验中, 我们研究四轮对话, 因此我们过滤了少于八句的对话, 并截取大于等于八句对话中的前八句。在以上条件下, 挑选5835组对话作为训练集, 200组作为测试集。图 2中分别给出了过滤后的数据集中话题、情感、意图的类别概率分布。从图中我们发现, 对话中情感为中性的话语占大多数, 意图为陈述和询问的话语占比高于其他两种意图。

图 3展示了同一轮对话中前一句的意图确定时, 后一句话的意图类别的概率分布。从图中我们发现对话中不同的角色之间的意图是相互影响。对话发生在前后两个角色之间, 后者的意

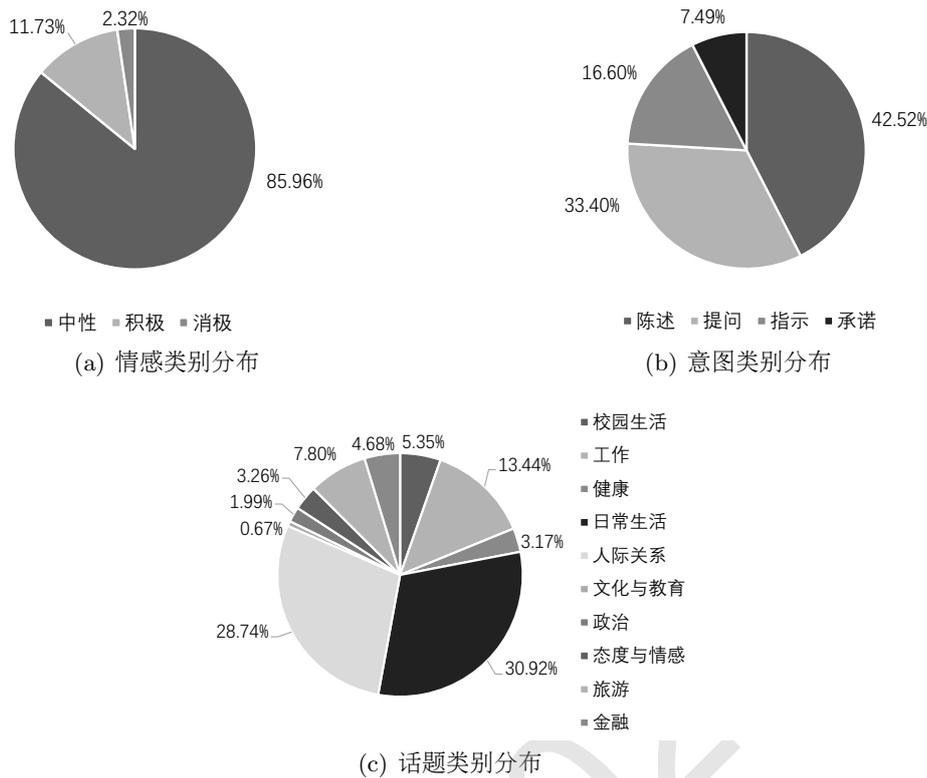


图 2. 情感、意图、话题类别概率分布

图常常会受到前者的影响，而前者是对话的发起方，处于主导地位。例如，提问和陈述往往是同时发生的，因为当有人向我们提问时，我们通常不会转移话题，而是礼貌地回复别人的问题。另外指示和承诺往往也是同时发生的，当有人向我们提出建议时，我们一般会对对方所提的建议做出回应。图 4显示了同一说话者前一句的情感确定的条件下，后一句的情感类别的概率分布。为了避免无情感话语的干扰，我们只统计了话语的情感为积极或者消极的情况。从图中我们看出相同情感同时出现的概率远远高于其他情感，这说明同一说话者的情感基调通常是保持不变的。基于上述分析，我们可以发现对对话的情感和意图识别在回复生成中是非常重要的。

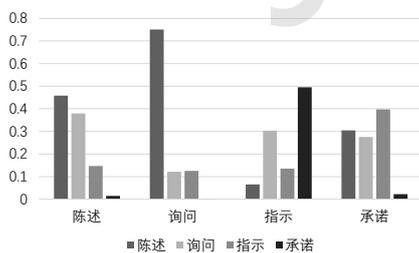


图 3. 同一轮对话中意图的影响

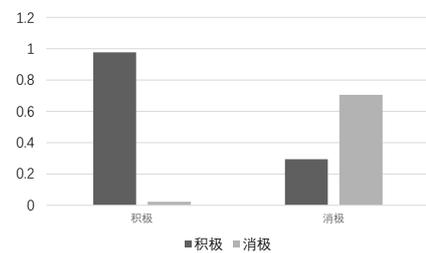


图 4. 同一说话者情感的影响

本文使用BLEU(Bilingual Evaluation Under-study) (Papineni et al., 2002)来衡量所产生的响应与地面真实响应之间的相关性。本文主要使用BLEU-1、BLEU-2和BLEU-3来评测实验效果。本文还使用词嵌入之间的余弦相似度来度量词之间的相似性，可分为三类：Average (Foltz et al., 1998)，Greedy (Rus and Lintean, 2012)和Extrema (Forgues et al., 2014)。Average计算句子级别的嵌入，而Greedy和Extrema则计算单词级别的余弦相似度。它们的区别在于，Greedy将句子中的平均单词向量作为句子的嵌入，而Extrema则采用这些单词向量的极值。

4.2 实验参数设置

为了获取最优模型，经调整本实验设置的相关参数如表 3所示。

参数	取值
Embedding层的输出维度	128
LSTM层的输出维度	128
话语最大长度	20
批次大小	64
迭代次数	20
dropout	0.2

表 3. DailyDialog基本信息统计

4.3 与基准模型比较

在前人关于对话回复生成的研究的基础上，我们选取了Seq2Seq, Multi, Dir-VHRED, ReCoSa, HRG五个模型进行对比实验。接下来，我们将分别介绍这五个模型。

- **Seq2Seq模型**: (Bahdanau et al., 2015)将前七句历史对话信息拼接成一个向量作为输入，为其构建一个LSTM模型，此LSTM模型的输出作为中间语义向量，然后解码生成对话回复。此模型为一个单输入模型。
- **Multi模型**: 将前七句话分别作为输入，为每个子句构建LSTM模型，将所有LSTM的输出平均值作为中间语义向量，然后解码生成对话回复。此模型为一个多输入模型。
- **Dir-VHRED模型**: (Zeng et al., 2019)使用Dirichlet分布来描述VHRED中的潜在变量。Dirichlet分布是贝叶斯统计中多项式分布的流行共轭先验，它可以是凹面或凸面，单调上升。
- **ReCoSa模型**: (Zhang et al., 2019)使用自注意力机制来更新上下文和被屏蔽的响应表示，并在解码过程中使用上下文和响应表示之间的注意力权重。
- **HRG模型**: (Zhang and Zhang, 2019)采用分层响应生成框架以自然和连贯的方式捕获对话意图。

模型名称	BLEU-1	BLEU-2	BLEU-3	Average	Greedy	Extrema
Seq2Seq	12.94	5.64	4.80	57.88	42.01	36.06
Multi	15.64	6.48	5.33	62.14	44.33	37.20
Dir-VHRED	10.90	3.82	2.26	59.92	41.26	32.70
ReCoSa	17.24	8.37	6.89	62.63	46.59	40.42
HRG	17.58	7.55	5.88	63.29	45.34	38.50
JTEA(Ours)	19.41	10.40	9.01	64.56	48.13	41.46

表 4. 与基线模型比较

表 4展示了我们的模型和基线模型比较的结果。从表中我们可以得出以下结论：

- 1) Multi模型比Seq2Seq模型表现好。因为Seq2Seq模型是将所有历史句子信息拼接作为输入序列，导致前面子句的语义信息被逐渐稀释掉，生成的中间语义向量不能充分提取历史信息中的特征。同时也证明了将历史信息中的每一个子句分别经过LSTM网络，取平均值作为中间语义向量更加合理。

- 2) 我们的模型相较于Multi模型，BLEU-1、BLEU-2、BLEU-3值分别提升了3.77、4.76、3.68个百分点，Average、Greedy、Extrema分别提升了2.42、3.8、4.26个百分点。而我们的模型是在Multi模型的基础上引入了主题、情感和意图的识别，这证明了对对话回复进行约束可以有效地提高生成回复的质量。
- 3) 我们的模型的实验结果超过了所有的基准模型，充分说明了我们提出的模型能有效地提高生成的对话回复的质量。

4.4 不同因素的影响

为了验证我们模型的有效性，将我们的模型与分别单独考虑话题、情感、意图预测模型进行对比实验。实验结果如表 5所示。我们共涉及了5组对比实验。Multi模型在上一节中已经介绍，不再赘述；Joint Topic模型是在Multi模型的基础上加入对话意图的识别；Joint Senti模型是在Multi模型的基础上加入话语情感的识别；Joint Act模型是在Multi模型的基础上加入话语意图的识别。

模型名称	BLEU-1	BLEU-2	BLEU-3	Average	Greedy	Extrema
Multi	15.64	6.48	5.33	62.14	44.33	37.20
Joint Topic	18.01	8.87	7.60	63.34	45.32	39.26
Joint Senti	16.89	7.74	6.34	62.74	43.93	37.32
Joint Act	17.97	8.77	7.46	63.22	45.50	38.84
JTEA(Ours)	19.41	10.40	9.01	64.56	48.13	41.46

表 5. 不同因素的影响

从表中可以发现，所有具有约束条件的模型(Joint Topic, Joint Senti, Joint Act, JTEA)都优于基准Multi模型，这表明所有的约束条件对于回复生成都是有效的。另外，我们的模型即考虑所有的约束条件优于单独考虑每个约束条件的模型，这表明我们应该集成所有约束条件来生成更高质量的回复。我们还可以发现情感的约束相对于主题和意图的约束效果要稍差一点，是因为在我们的语料中绝大部分话语的情感都是中立的，情感对回复的影响相对较小。

4.5 案例分析

我们对基线Multi模型和我们的模型生成的对话回复进行对比分析，表 6给出了三组对话示例，我们截取了对话的主要内容且对话内容都已翻译为中文展示。

从第一组示例中我们可以看出，此轮对话的主题是校园生活。对于最后说话者A的提问，Multi模型没能充分的理解该组对话的语义信息，所以生成了“你可以确定”这样和对话内容毫无联系的回复。而我们的模型因为加入了对主题的识别，所以生成了与对话主题高度相关且自然合理的回复。在第二组对话中，我们发现最后说话者A的意图是“指示”。在同一轮对话中，当前一句的意图为“指示”时，后一句的意图最大概率为“承诺”。我们的模型因为加入了对意图的识别，生成了意图为“承诺”的回答，而multi模型则生成了意图为“陈述”的回答，显然我们生成的回复更加的合理。在第三组实例中，我们的模型生成的回复在意图上显然更加合理。另外，根据4.1小节中的分析，同一说话者的情感基调往往是不变的。我们的模型因为加入了对情感的识别，生成了带有积极情感倾向的回复。

5 总结

在大数据不断发展的今天，人机对话系统是人机交互领域一个非常重要的研究方向，开放域聊天机器人的研究受到了广泛关注。这使得提高对话回复的质量尤为重要。

考虑到在对话往往是围绕特定的主题且对话中的每个子句具有明显的情感和意图倾向，本文提出了一种基于对话约束的回复生成模型。以往的对话生成模型总是倾向于生成类似“好的”、“我不知道”的安全回复，虽然这样的回复看起来合理，但其实这样的模糊回复意义并不大，信息量很低。为了解决这个问题，我们在基于LSTM网络的Seq2Seq模型基础上引入了对对话的话题、情感和意图的识别，使得生成具有合理的情感和意

示例1	
A	我如何申请美国的大学?
B	您应该去图书馆查找有关美国大学的信息, 然后写信给招生办公室。(中性, 指示)
A	处理所有程序需要多长时间?(中性, 提问)
Multi生成的回复	你可以确定。(中性, 陈述)
JTEA(Ours)模型生成的回复	如果一切顺利, 需要3到6个月。(中性, 陈述)
示例2	
A	嗨, 迈克尔。你怎么了? 你看起来很生气。(中性, 询问)
B	不, 我只是检查我的体重, 我越来越胖。(消极, 陈述)
A	你为什么不和我一起锻炼呢? 如果坚持下去, 它会起作用。来吧, 走吧!(中性, 指示)
Multi生成的回复	是的, 我有一杯酒。(中性, 陈述)
JTEA(Ours)模型生成的回复	好的, 请帮助我更好的完成它。(中性, 承诺)
示例3	
A	您好, 我是ABC公司的露西。我打电话看你是否做出决定。您是我们正在寻找的合适人选。(中性, 提问)
B	是的, 我决定与您的公司合作。我的荣幸。(积极, 陈述)
A	好的, 请下个星期一上午9点到我的办公室。(中性, 指示)
Multi生成的回复	那其他男人呢?(中性, 提问)
JTEA(Ours)模型生成的回复	没问题。谢谢你给我打电话。(积极, 承诺)

表 6. 生成回复示例对比

图倾向且与对话主题相关的回复。实验结果表明: 该方法与传统的Seq2Seq方法相比, 在BLEU值、Average、Greedy、Exrema的评测上有了较大的提升。

由于本文对话数据仅限于标准的书面日常对话, 有一定的局限性。因此, 本文的下一步工作将进一步考虑更加专业的, 更加贴近实际的对话文本。另外, 研究历史信息中各个子句之间的相互影响, 对对话中的句子结构进行建模, 进一步提升情感、意图识别的效果。

参考文献

- Dzmitry Bahdanau, Kyunghyun Cho, and Yoshua Bengio. 2015. Neural machine translation by jointly learning to align and translate. In Yoshua Bengio and Yann LeCun, editors, *3rd International Conference on Learning Representations, ICLR 2015, San Diego, CA, USA, May 7-9, 2015, Conference Track Proceedings*.
- Peter F. Brown, Stephen Della Pietra, Vincent J. Della Pietra, and Robert L. Mercer. 1993. The mathematics of statistical machine translation: Parameter estimation. *Comput. Linguistics*, 19(2):263–311.
- Kyunghyun Cho, Bart van Merriënboer, Çağlar Gülçehre, Dzmitry Bahdanau, Fethi Bougares, Holger Schwenk, and Yoshua Bengio. 2014. Learning phrase representations using RNN encoder-decoder for statistical machine translation. In Alessandro Moschitti, Bo Pang, and Walter Daelemans, editors, *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing, EMNLP 2014, October 25-29, 2014, Doha, Qatar, A meeting of SIGDAT, a Special Interest Group of the ACL*, pages 1724–1734. ACL.
- Peter W Foltz, Walter Kintsch, and Thomas K Landauer. 1998. The measurement of textual coherence with latent semantic analysis. *Discourse processes*, 25(2-3):285–307.
- Gabriel Fongues, Joelle Pineau, Jean-Marie Larchevêque, and Réal Tremblay. 2014. Bootstrapping dialog systems with word embeddings. In *Nips, modern machine learning and natural language processing workshop*, volume 2.
- Daniel Fried, Mitchell Stern, and Dan Klein. 2017. Improving neural parsing by disentangling model combination and reranking effects. *arXiv preprint arXiv:1707.03058*.

- Ishaan Gulrajani, Faruk Ahmed, Martin Arjovsky, Vincent Dumoulin, and Aaron C Courville. 2017. Improved training of wasserstein gans. In *Advances in neural information processing systems*, pages 5767–5777.
- Sepp Hochreiter and Jürgen Schmidhuber. 1997. Long short-term memory. *Neural computation*, 9(8):1735–1780.
- Zhiheng Huang, Wei Xu, and Kai Yu. 2015. Bidirectional LSTM-CRF models for sequence tagging. *CoRR*, abs/1508.01991.
- Ankit Kumar, Ozan Irsoy, Peter Ondruska, Mohit Iyyer, James Bradbury, Ishaan Gulrajani, Victor Zhong, Romain Paulus, and Richard Socher. 2016. Ask me anything: Dynamic memory networks for natural language processing. In *International conference on machine learning*, pages 1378–1387.
- Yann LeCun, Yoshua Bengio, and Geoffrey Hinton. 2015. Deep learning. *nature*, 521(7553):436–444.
- Jiwei Li, Michel Galley, Chris Brockett, Jianfeng Gao, and Bill Dolan. 2016. A diversity-promoting objective function for neural conversation models. In Kevin Knight, Ani Nenkova, and Owen Rambow, editors, *NAACL HLT 2016, The 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, San Diego California, USA, June 12-17, 2016*, pages 110–119. The Association for Computational Linguistics.
- Jiwei Li, Will Monroe, Tianlin Shi, Sébastien Jean, Alan Ritter, and Dan Jurafsky. 2017a. Adversarial learning for neural dialogue generation. In Martha Palmer, Rebecca Hwa, and Sebastian Riedel, editors, *Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing, EMNLP 2017, Copenhagen, Denmark, September 9-11, 2017*, pages 2157–2169. Association for Computational Linguistics.
- Yanran Li, Hui Su, Xiaoyu Shen, Wenjie Li, Ziqiang Cao, and Shuzi Niu. 2017b. Dailydialog: A manually labelled multi-turn dialogue dataset. *arXiv preprint arXiv:1710.03957*.
- Brendan D. McKay and Adolfo Piperno. 2014. Practical graph isomorphism, II. *J. Symb. Comput.*, 60:94–112.
- Lili Mou, Yiping Song, Rui Yan, Ge Li, Lu Zhang, and Zhi Jin. 2016. Sequence to backward and forward sequences: A content-introducing approach to generative short-text conversation. In Nicoletta Calzolari, Yuji Matsumoto, and Rashmi Prasad, editors, *COLING 2016, 26th International Conference on Computational Linguistics, Proceedings of the Conference: Technical Papers, December 11-16, 2016, Osaka, Japan*, pages 3349–3358. ACL.
- Kishore Papineni, Salim Roukos, Todd Ward, and Wei-Jing Zhu. 2002. Bleu: a method for automatic evaluation of machine translation. In *Proceedings of the 40th annual meeting on association for computational linguistics*, pages 311–318. Association for Computational Linguistics.
- Vasile Rus and Mihai Lintean. 2012. An optimal assessment of natural language student input using word-to-word similarity metrics. In *International Conference on Intelligent Tutoring Systems*, pages 675–676. Springer.
- Iulian V Serban, Alessandro Sordoni, Yoshua Bengio, Aaron Courville, and Joelle Pineau. 2016. Building end-to-end dialogue systems using generative hierarchical neural network models. In *Thirtieth AAAI Conference on Artificial Intelligence*.
- Louis Shao, Stephan Gouws, Denny Britz, Anna Goldie, Brian Strope, and Ray Kurzweil. 2017. Generating high-quality and informative conversation responses with sequence-to-sequence models. *arXiv preprint arXiv:1701.03185*.
- Alessandro Sordoni, Michel Galley, Michael Auli, Chris Brockett, Yangfeng Ji, Margaret Mitchell, Jian-Yun Nie, Jianfeng Gao, and Bill Dolan. 2015. A neural network approach to context-sensitive generation of conversational responses. *arXiv preprint arXiv:1506.06714*.
- Ilya Sutskever, Oriol Vinyals, and Quoc V. Le. 2014. Sequence to sequence learning with neural networks. In Zoubin Ghahramani, Max Welling, Corinna Cortes, Neil D. Lawrence, and Kilian Q. Weinberger, editors, *Advances in Neural Information Processing Systems 27: Annual Conference on Neural Information Processing Systems 2014, December 8-13 2014, Montreal, Quebec, Canada*, pages 3104–3112.

- Chongyang Tao, Shen Gao, Mingyue Shang, Wei Wu, Dongyan Zhao, and Rui Yan. 2018. Get the point of my utterance! learning towards effective responses with multi-head attention mechanism. In *IJCAI*, pages 4418–4424.
- Ashwin K. Vijayakumar, Michael Cogswell, Ramprasaath R. Selvaraju, Qing Sun, Stefan Lee, David J. Crandall, and Dhruv Batra. 2016. Diverse beam search: Decoding diverse solutions from neural sequence models. *CoRR*, abs/1610.02424.
- Oriol Vinyals and Quoc V. Le. 2015. A neural conversational model. *CoRR*, abs/1506.05869.
- Tsung-Hsien Wen, Milica Gasic, Nikola Mrksic, Pei-Hao Su, David Vandyke, and Steve Young. 2015. Semantically conditioned lstm-based natural language generation for spoken dialogue systems. *arXiv preprint arXiv:1508.01745*.
- Chen Xing, Wei Wu, Yu Wu, Jie Liu, Yalou Huang, Ming Zhou, and Wei-Ying Ma. 2017. Topic aware neural response generation. In *Thirty-First AAAI Conference on Artificial Intelligence*.
- Kun Xiong, Anqi Cui, Zefeng Zhang, and Ming Li. 2016. Neural contextual conversation learning with labeled question-answering pairs. *arXiv preprint arXiv:1607.05809*.
- Min Zeng, Yisen Wang, and Yuan Luo. 2019. Dirichlet latent variable hierarchical recurrent encoder-decoder in dialogue generation. In *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)*, pages 1267–1272.
- Bo Zhang and Xiaoming Zhang. 2019. Hierarchy response learning for neural conversation generation. In *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)*, pages 1772–1781.
- Ruqing Zhang, Jiafeng Guo, Yixing Fan, Yanyan Lan, Jun Xu, and Xueqi Cheng. 2018. Learning to control the specificity in neural response generation. In *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pages 1108–1117.
- Hainan Zhang, Yanyan Lan, Liang Pang, Jiafeng Guo, and Xueqi Cheng. 2019. Recosa: Detecting the relevant contexts with self-attention for multi-turn dialogue generation. *arXiv preprint arXiv:1907.05339*.