



基于多轮交互的人机对话系统综述

摘要

近些年来,人机对话系统作为自然语言处理的重要问题之一受到了越来越多的关注.基于大数据的深度学习的方法在对话系统中被广泛应用.本文首先介绍了人机对话系统的研究背景,然后以基于多轮交互的对话系统为例,着重介绍了任务型和非任务型对话系统的主要类型和目前的研究进展,并对评估对话系统的主要方法进行了概述.最后,结合当前研究现状,对多轮交互的人机对话系统的研究方向进行了展望.

关键词

人机对话系统;自然语言处理;深度学习;人工智能

中图分类号 TP181;TP391

文献标志码 A

0 引言

自然语言作为人类在自然发展过程中产生的交流语言,是人类用来直接表达情感和交流信息的主要工具.早在1950年,图灵提出的“图灵测试”被认为是自然语言处理思想的开端.随着计算机和互联网的广泛应用、算力的不断提升,计算机对自然语言信息的处理能力也得到了空前的提高,而随着网络快速传播,海量的文本信息中的文本挖掘、信息提取、跨语言信息处理、人机交互等应用需求急剧增长.作为人工智能问题中的重要问题之一,具有众多应用场景和研究价值的自然语言处理受到了越来越多的关注.

自然语言处理(Natural Language Process, NLP)问题包括机器翻译(Machine Translation)、文本摘要(Text Summarization)、问题生成(Question Generation)、问答系统(Question Answering)、对话生成(Dialogue Generation)、语义分析(Dialogue Generation)、图像理解(Image Captioning)等诸多任务.这些任务之间既存在关联,也有独立于其他任务的特性,其中对话生成作为应用场景相对广泛的问题之一,成为了近期的热门研究话题.

随着人机交互技术的进步,类似“环境智能(Ambient Intelligence)”这类课题更多地强调用户友好性和智能交互性.为了确保自然的智能交互,非常有必要研发安全可靠的交互技术以在人机之间建立沟通的桥梁.有鉴于此,过去的几十年有很多研究致力于模仿人-人交互的模式来构建人机交互系统,我们称之为对话系统(Spoken Dialogue Systems, SDSs)^[1].从时间线上来看,一般从早期的聊天机器人 ELIZA 开始讨论对话系统的发展. ELIZA Chatbot 是 Joseph Weizenbaum 在1966年开发的聊天机器人,最初作为早期自然语言处理计算机程序,模拟一位心理治疗师, ELIZA 通常也被视为第一个聊天机器人^[2].在此之后,微软推出了针对 Office 的办公套件助手 Clippy,可以被认为是最早推向商用的人机对话系统.但是由于这个助手更多的是作为问答系统中的一方而存在,并没有真正地达到人机对话的水平,且准确率较差,因而在后来的 Office 版本中被移除.2006年之后,随着深度学习方法的广泛应用,包括对话系统在内的多个自然语言处理问题得到了突破性的发展,人机对话系统中的答非所问的情况得到了有效的改善.2016年开始,包括微软^[3-4]、苹果^[5]、谷歌、亚马逊等在内的多家科技行业巨头都推出了自己的语音助

收稿日期 2019-05-20

资助项目 国家自然科学基金(61727809)

作者简介

陈健鹏,男,硕士生,研究方向为对话生成.jpchen@mail.ustc.edu.cn

马建辉(通信作者),男,博士,讲师,研究方向为大数据分析挖掘及可视化.jianhui@ustc.edu.cn

¹ 中国科学技术大学 大数据分析与应用安徽省重点实验室,合肥,230027

手,图1展示了其中几种不同的人工智能助手.作为在移动平台上最容易接受的人机交互沟通方式,对话系统开始成为众多开发者和研究人员关注的焦点.



图1 不同的人工智能助手

Fig.1 Different kinds of AI assistant

智能对话系统按照表现形式一般分为单轮对话和多轮对话两种.单轮对话与传统问答系统类似,属于对话系统的初级应用,通过一问一答的形式完成用户的简单请求或意图,或者执行一些特定操作.单轮对话一般不存在指代省略或者上下文连贯性问题,其生成技术一般应用在电商平台客服等产品中.相对于单轮对话,多轮对话中存在人机的多轮交互,通过这样多轮交互的形式完成连续的主题对话(开放域的多轮对话)或者对用户的复杂意图或请求加以完成(封闭域的多轮对话).多轮对话对聊天的上下文、指代省略的补全和复杂需求的明确等问题都有着更为复杂的要求,也更贴近包括咨询、推荐、服务需求、闲聊等现实情况的应用场景.

早期的对话系统的研究,基本都是采用基于符号和规则的方法,至今依然是主流的人机对话系统的解决方案之一.这种方法依赖于专家手动设置的规则和一定的语言模版,解释性和可修复性较好,但是拓展性较差,只能适用于解决单轮对话范围内的一些简单问题.随着更多全新完备的语料库出现和计算硬件能力的极大升级,对多轮交互人机对话系统的研究开始具备合适的研究基础.与此同时,统计学习方法开始被运用在人机对话领域,使当时的语音识别率从70%提升到了90%,对话系统也开始从理论走向商用.从2001年开始,人们开始引入深度学习的方法来进行对话策略学习,从最初的词向量到2013年word2vec^[6]、神经语言模型、词嵌入模型^[7]、Seq2Seq模型相继被提出,对多轮交互的人机对话系统的研究逐渐成为了热门的研究课题.

1 基于多轮交互的人机对话系统主要类型及解决方案

1.1 任务型对话

任务型对话是对话系统中比较经典的一类应用

场景,在多轮交互的任务型对话系统中,用户有着明确的服务获取需求,并且用户在对需求进行表述时可能存在严重的上下文省略,因而需要系统进行进一步询问或根据上下文、用户信息等额外信息以补充获得完整的需求描述并提供最优的解决方案^[8].图2中展示了一个多轮交互的任务型对话系统的例子.

User: I want a cup of coffee.
 Agent: Same as before? Tall hot macchiato and deliver to No.1199 Minsheng Road, Pudong District, Shanghai?
 User: I want iced mocha today.
 Agent: Sure, please pay.
 User: Payment completed.

图2 一个多轮交互的任务型对话例子^[9]

Fig.2 An example of multiple-round task-oriented dialogue^[9]

相对于非任务型对话系统,任务型对话系统有着更明确的完成目标的特性,并且一般也是领域独立的.本部分对任务型对话的几种基本方法进行阐述.

1.1.1 基于管道方法

基于管道的方法是任务型对话的一种经典的解决方案,其主要结构包括自然语言理解(Natural Language Understand)、对话状态追踪(Dialogue State Tracking)、对话策略学习(Policy Learning)和自然语言生成(Natural Language Generation)4个流程,如图3所示.

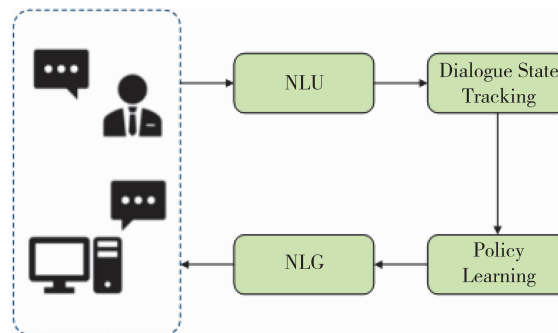


图3 基于管道的方法流程

Fig.3 Structure of pipeline-based methods

1) 自然语言理解

自然语言理解的输入为用户的语句,主要完成3种任务:槽标记(slot tagging)、领域识别(domain detection)和意图理解(intent determination).在基于管

道的方法中,这3种任务被依次完成.如图4所示的是其中一个例子,从上至下依次为领域识别、意图理解和槽标记结果.准确率和F1评分是评价此类模型预测质量的最常用衡量指标.作为对话系统中的预处理模块,自然语言理解对整个系统的生成质量有着重要影响^[10].

| | | | | | | |
|-----|------|--------|----------|------------|-------|---------|
| | find | recent | comedies | by | james | cameron |
| 领域 | | | | | | |
| 意图 | | | | find_movie | | |
| 槽标记 | O | B-date | B-genre | O | B-dir | I-dir |

图4 一个基于“内部-外部-开始”(Inside-Outside-Beginning, IOB)表征的NLU输出实例^[11]

Fig. 4 An example output of NLU with the IOB representation^[11]

细化来说,领域识别将用户的服务需求划分到某一事先定义好的领域下,以针对性地进行后续分析和作出回答.意图理解则是针对用户的表述中的显式意图和隐式意图做出识别和理解.显式意图主要包括用户的某些明确的需求,例如“购买机票”等具体的需求;隐式需求则是用户在表述中隐性包含的需求,可能通过对表述和上下文的综合判断来体现,例如“某部电影非常好看”可能包含与看电影相关的需求.

容易看出,前两个任务都是基于用户的输入语句进行所属领域或者指代意图的推断,属于分类问题. Ravuri 和 Stolcke 在 2015 年发现基于循环神经网络(Recurrent Neural Network, RNN)的方法在这类问题上效率更高^[12]. 2016 年以后,包括卷积神经网络(Convolutional Neural Network, CNN)^[13-14]在内的多种基于深度学习的多分类方法已经被成功运用到了这一类任务中^[15-16],并且取得了不错的效果.

与领域推断和意图理解不同,槽标记是三类任务中较为复杂的一类任务.槽标记对句子中的语义槽序列进行标记,语义槽是根据不同的场景预先定义的,输入是句子中的单词序列,输出为一个槽(slot)/语义标记(semantic label)序列^[15,17].语义槽主要包括两种:一种是句子级别的语义槽,包括用户需求类型和语句类型;一种是词级别的语义槽,包括实体识别和语义槽填充等.图4展示的就是一个基于 Inside-Outside-Beginning (IOB) 格式的标记结果^[18].大量基于深度神经网络的方法^[19-20]被应用在这个问题上,比如 Hakkani-Tür 在 2016 年的工作中

将长短期记忆(Long-Short Term Memory, LSTM)网络运用在一个包括领域识别、意图识别和槽标记任务在内的联合训练模型上,获得了非常好的效果^[11].

2) 对话状态追踪

在 NLU 完成对对话内容的语义表征后,会形成一个包含用户在本轮对话中的所有需求信息的状态信息,用来估计用户在本轮对话中的目标.对话状态的追踪是确保对话系统健壮性的核心组成部分.

对话状态追踪的核心是利用对话中的信息对预定义的对话的细节框架进行填充,当框架中仍然存在未能填补完成的细节时,系统会向用户做出进一步询问以做出进一步补充.早期的对话状态追踪主要是通过专家确定的规则来进行的,抑或是通过诸如条件随机场的统计学习方法进行的^[21].在那之后,利用神经网络的方法开始获得关注,包括深度神经网络(Deep Neural Network, DNN)、循环神经网络(Recurrent Neural Network, RNN)等的新方法被应用到了这一问题中^[22-23].

Lei 等^[24]在 2018 年的一篇论文中提出了一个名为 Sequicity 的对话系统框架,框架中定义了一种称为“belief spans”的结构来表征对话状态,结构中包含两种槽位,一种用来表示当前轮次对话的信息的 inform_slot 槽位,一种用来表示请求的 request_slot 槽位,用来存储可请求的插槽,通过结合基于复制机制的 CopyNet,在解决诸如人名、地名等的未登陆词(Out Of Vocabulary, OOV)问题基础上减少了模型参数且提升了训练效果,大大提升了任务型对话系统的表现.

3) 对话策略学习

通过对对话状态的表征后,系统利用离线方式从对话状态表征中学习出一定的对话模式,作为指导人机对话生成的策略,从而完成对话系统从“理解识别”到“生成对话”的转换.对话策略利用当前对话状态的表征向量产生下一步最优的回复.对话策略的学习主要有监督学习和强化学习两种解决方案,不论采用哪一种方案,策略的学习都是一个从训练中更新模型以获得提升的过程^[25].学习出一个好的对话生成策略通常需要大量的训练数据支持,但是通过专家系统产生的规则作为初始策略进行训练可以大大加快模型的训练速度^[26].相较于监督学习的方法,通过端到端的强化学习方法,在单任务策略学习、多任务策略学习、多领域对话策略学习等方面均有非常好的效果.

4) 自然语言生成

自然语言生成(NLG)过程将基于抽象的对话策略做出的决策转换成自然语言表述的句子,作为最终的输出结果.一个好的生成结果,应该在合适度、对话流畅度、语句易读性和句子的多样性上均有较为优秀的效果^[27].NLG对于对话系统的自然度有着极为重要的影响,因而也会极大地影响到人机对话系统的用户体验.

NLG有多种解决方案,包括基于模版和规则的生成方法、基于数据驱动的生成方法以及基于深度学习的生成方法.早期的方法大多使用人工制定的规则和模版来完成^[28],优点是生成效果精准,但是缺点也非常明显:领域局限性过强,且可拓展性非常差,生成语句的效果非常依赖于人工制定规则的好坏.苹果公司的个人助手 Siri 在早期就采用了基于模版和规则的语言生成策略,造成的结果是在完成一些特定指令和对一些特定问题进行问答时,Siri 的表现出色,但是在其他情况下,Siri 的表现变得极为糟糕.针对这样的情况,基于数据驱动的生成方法被提出^[29],通过将检索方法和统计学习相结合,有效地提高了 NLG 的准确度和可拓展性,但是基于索引的方法依旧不够灵活,在句子长度和提供有效回复的效率之间无法找到很好的平衡.

2015 年以后,包括 Wen 等提出的基于语义控制的 LSTM(SC-LSTM)^[30]在内的多种利用神经网络的方法^[31]被应用到这一问题的解决中,其结构如图 5 所示.通过语句规划模块(图中下半部分),利用额外信息的添加达到使生成的语句既能完成用户的服务需求,同时还能对结果的语义进行控制,从而提升生成的效果.

基于 SC-LSTM 的方法,新的方法在多方面进行了拓展,包括利用多领域学习以降低训练生成模型时需求的数据量^[32],以及使用分层方法对利用语言学的模式对生成模型进行改进^[33],以取得更好的效果.

1.1.2 基于端到端的方法

传统的基于管道的方法,各个对话处理流程都进行了模块化处理,模块化的优势就是构建较为灵活、分块优化,可以以较为独立的方式进行.然而相对的,每个模块的复杂化也导致系统整体优化变得十分困难,且分模块的优化对整个系统的联合优化效果的影响可能不够明显^[34].随着基于神经网络的深度学习技术开始被应用到多个领域且取得了不错

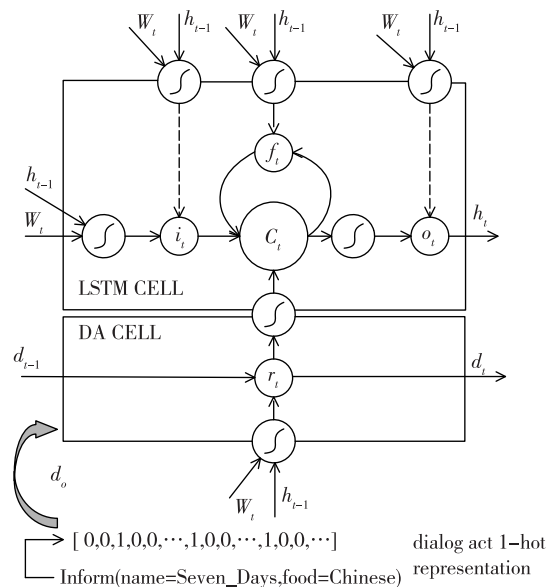


图 5 一个语义控制的 LSTM (SC-LSTM) 结构^[30]
Fig. 5 A semantic controlled LSTM (SC-LSTM) cell^[30]

的效果^[30,35-36]后,基于神经网络的联合优化方式开始成为研究热点,基于端到端的方法使得研究人员能够利用更为海量的数据和强大的计算力,从中挖掘更有价值的规律和特征,模型的可拓展性也获得了显著提升,而且规范化的输入和输出也能规避人为特征工程所带来的不确定性和繁重的工作量.

较早期的基于端到端的对话系统中,对外部知识库的引用使用的还是基于无差别的知识库查询操作,这样的操作模式导致系统无法针对用户需求中的非确定性需求做出查询,也无法有效地利用用户的反馈对系统整体做出有效的优化^[37].文献[38]提出了一种基于端到端的可训练的键值对索引网络(Key-Value Retrieval Network),利用基于注意力机制的键值对索引机制对知识库中的内容进行搜索,从而可以在知识库中获得更多的额外信息.关于注意力机制,将在 1.2.2 节详细解释.

2014 年,Google Brain 团队和 Yoshua Bengio 团队的两篇论文中均提出了 Seq2Seq 方法^[39-40],通过神经网络模型将一个作为输入的序列映射为一个作为输出的序列,通常使用 RNN、门控循环单元(Gated Recurrent Unit, GRU)、LSTM 等作为基础结构,这一过程由编码输入(encoder)与解码输出(decoder)两个环节组成.关于 Seq2Seq 的更多细节将在 1.2.2 节详细说明.

然而基于 Seq2Seq 的方法存在需求训练数据过

于庞大的问题,且单纯使用这一结构会导致对话策略的学习中对对话控制的能力偏弱.针对这一问题,强化学习的方法被应用到策略学习中,极大地提高了系统的鲁棒性,同时解决了 Seq2Seq 模型对训练数据的规模需求^[10,41-42].需要说明的是,很多端到端的学习方法不仅针对任务型对话系统适用,对非任务型对话系统同样适用且能保持较好的效果.

1.2 非任务型对话

不同于任务型对话,非任务型对话是一种面向开放域的人机对话系统.由于这类对话系统通常不依赖于外部知识库,因而不包含类似 1.1 节中所描述的 4 个基本的自然语言处理组件^[43].多轮交互情境下,非任务型对话系统需要能够保持上下文一致性,在稳定持续进行某一聊天主题的同时及时根据用户输入切换主题,图 6 展示了一个多轮交互场景下的非任务型对话生成系统的例子.

A: Where are you going? (1)
 B: I'm going to the police station. (2)
 A: I'll come with you. (3)
 B: No, no, no, no, you're not going anywhere. (4)
 A: Why? (5)
 B: I need you to stay here. (6)
 A: I don't know what you are talking about. (7)
 ...

图 6 一个多轮交互的非任务型对话例子^[44]

Fig. 6 An example of multiple-round non-task-oriented dialogue^[44]

非任务型对话常用于聊天机器人(Chatbot)中,其生成方式和以完成用户需求为明确目标的任务型对话系统有所不同,主要分为检索式(retrieved-based methods)和生成式(generative methods).

基于检索的方法在回复的流畅性上有较好的优势,效果也易于评估,但与之相对的,这种方法对上下文的敏感度相对不足,容易产生随机性的回复,且限制条件较多^[45].基于生成的方法优势在于端到端学习,因而可以很好地避免人工造成的影响因素过多.同时,基于上下文的生成方法对上下文具备很好的敏感度,因而可以做出更多可控和灵活的回复.但同时,基于生成的方法也比较难以进行评估,且容易产生无趣的单调性回复,同时模型内部架构对生成效果有非常重要的影响,因而这种方法具有一定难度.以下分别对其中的几种比较常见的生成方法进行描述.

1.2.1 基于检索的方法

基于检索的方法的主要思想是在多个候选回答中选择一个合适的回答作为输出,这种方法的核心是已知的对话信息和回复之间的匹配度的确定.由于语义鸿沟的存在,信息-回复匹配度算法需要从多方面衡量两者之间的关联度^[46].

早期的研究主要关注于单轮对话中的回复匹配的问题,将用户的输入语句进行编码,同时对候选回复同样进行编码,以这两个编码后的向量计算两者之间的相关度^[47]:

$$\text{match}(\mathbf{x}, \mathbf{y}) = \mathbf{x}^T \mathbf{A} \mathbf{y}, \quad (1)$$

其中 \mathbf{x} 表示输入语句的表征向量, \mathbf{y} 表示候选回复的表征向量, \mathbf{A} 是一个预定义的矩阵.在此之后,基于深度学习的方法改进了这个计算模型,使得这类相关度的计算准确度获得了很大的提高,包括 LDA 主题模型^[48]和基于 CNN 的模型结构^[46]使得对相关度的刻画更为准确,同时也加速了在富文本场景下模型的回复速度.

之后的研究开始关注于多轮对话中的回复匹配问题.多轮对话的输入为当前的消息和之前的对话输入,输出仍然是将一个与上下文最为相关的回复.多轮输出场景下,问题的难点在于对输入上下文中的关键信息和连贯性特征的寻找,直接套用单轮对话下的选择策略很容易导致丢失上下文中的信息或者失去对话连贯性.利用多层 RNN 结构(如图 7 所示),将上下文和候选回复分别编码到对应的向量中,然后计算两个向量之间的匹配度分数.这种做法利用了 RNN 的记忆特点,将候选回复与上下文进行多层次关联,以不同策略选择前文中的对话内容,对上下文向量的形成方式做出改进,从多方面改进了生成效果^[49].




图 7 使用 RNN 结构同时编码上下文和候选回复^[49]

Fig. 7 Encode context and candidate responses with RNN cells^[49]

1.2.2 基于生成的方法

基于检索的方法是一种基于“查询”到“结果”的转换过程的生成方法,因而在生成结果的合适度上相对不足,而查询的成本和外部知识库规模的正相关也使得其生成规模受到了限制.在此背景下,大量高质量语料集的出现,各类深度学习的方法的提出和在机器翻译、文本摘要等领域的成功应用,使得对基于生成的方法的研究逐渐流行起来.生成模型利用已有语料进行学习,针对用户的输入产生合适的新回复,从而克服了一般的基于检索方法对外部知识的规模限制.

本节首先介绍经典的序列到序列生成模型,针对这个经典模型可能存在的问题,我们讨论了一些有效的改进方式.同时还说明了一种利用强化学习进行训练的新的策略学习方法,这种方法以全新的思路有效地提升了生成对话的质量.

1) Seq2Seq

序列到序列(Sequence-to-Sequence, Seq2Seq)模型又称作编码器-解码器(Encoder-Decoder)模型,是完全数据驱动的网络模型.作为一种非常重要且流行的文本生成模型,Seq2Seq模型在包括文本摘要、机器翻译、词句法分析方面都有比较成熟的应用^[39].

经典的Seq2Seq模型如图8(<https://zhuanlan.zhihu.com/p/28054589>)所示.模型中,Encoder和Decoder常用一些序列模型做基本结构,如RNN、gate-RNN或LSTM^[50]等.定义输入序列(信息) $X = \{x_1, x_2, x_3, \dots, x_T\}$ 为一个包含 T 个单词的输入序列,定义 $Y = \{y_1, y_2, y_3, \dots, y_{T'}\}$ 为包含 T' 个单词的输出序列(回复),模型通过不断调整参数,尽可能地接近理想输出序列 Y_{final} .




图8 经典的Seq2Seq模型结构

Fig. 8 Structure of typical Seq2Seq model

Encoder首先对输入序列进行编码,将输入通过非线性变换转换成中间语义表示:

$$C = \mathcal{F}(h_1, h_2, h_3, \dots, h_T). \quad (2)$$

h_i 为 x_i 对应的中间语义表示.上下文向量 C 的获取方式有多种,最简单的方法就是把Encoder的最后一个

隐状态直接赋值给 C ,或者对最后一层的隐状态进行一定变换,也可以是对所有隐状态进行变换后进行一定组合,这就构成了Encoder模型的3种基本架构.

得到 C 之后,Decoder网络对得到的 C 进行解码,将 C 作为初始状态 h_0 输入到Decoder中,或者将 C 作为Decoder的每一步的输入,计算预测一个概率分布 $P(y|x)$ 以决定下一个要输出的单词 y_i .

$$y_i = \arg \max P(y_i) = \prod_{t=1}^T p(y_t | \{y_1, \dots, y_{t-1}\}, C). \quad (3)$$

通过计算输入与输出之间的损失函数并通过调整参数最小化损失,使训练效果不断优化.

2) HRED模型

基于RNN的Seq2Seq模型使得其能在长达50个词的句子中取得很好的效果^[51],但是对于多轮对话来说,对话记录的长度往往不止50个单词,此时Seq2Seq就开始容易产生不相关的无意义回答,且对于多轮对话,Seq2Seq缺乏对长期上下文的评估.为了解决这一问题,层级化的模型思路被应用到问题中以解决对句子长度的限制^[52-53],其中一个流行且有效的方案就是HRED(Hierarchical Recurrent Encoder-Decoder)模型^[54].

图9中展示的是两层的HRED模型在连续两轮对话中的运作结构,从前文获得信息生成“克利夫兰印度艺术馆”这个更贴合上下文的回复的生成过程.两层模型结构一层在单词角度进行编解码,一层在对话轮层面上进行编解码.将对话看成是多个句子的序列,单词层面的RNN编码器对句子进行编码形成一个句子的表征向量,然后上下文层面的RNN编码器对已经得到的句子向量进行编码,从而获得会话的历史信息,最后将获得的会话历史信息作为RNN解码器的输入,预测相应的回答.

HRED模型有效地将历史会话信息应用到了Seq2Seq结构中,解决了对句子长度的限制,同时使得会话的历史信息能有效地在多轮对话中传递.这一模型还能有效解决限制一般RNN网络最大可编码长度的梯度消失问题^[55].从效果上来说,基于层级方法使得对话的上下文相关性有了显著的提高.在之后的工作中,Serban等提出了一种基于主题变量的VHRED(Variable Hierarchical Recurrent Encoder-Decoder)模型^[56],拓展了HRED的效果,通过在最终的优化目标中加入一个高维的随机主题变量,减少了回复中的“无趣”回应的产生概率,只会判断必须要产生此类回复时才会产生“无趣”回复,提高了回复的多样性.

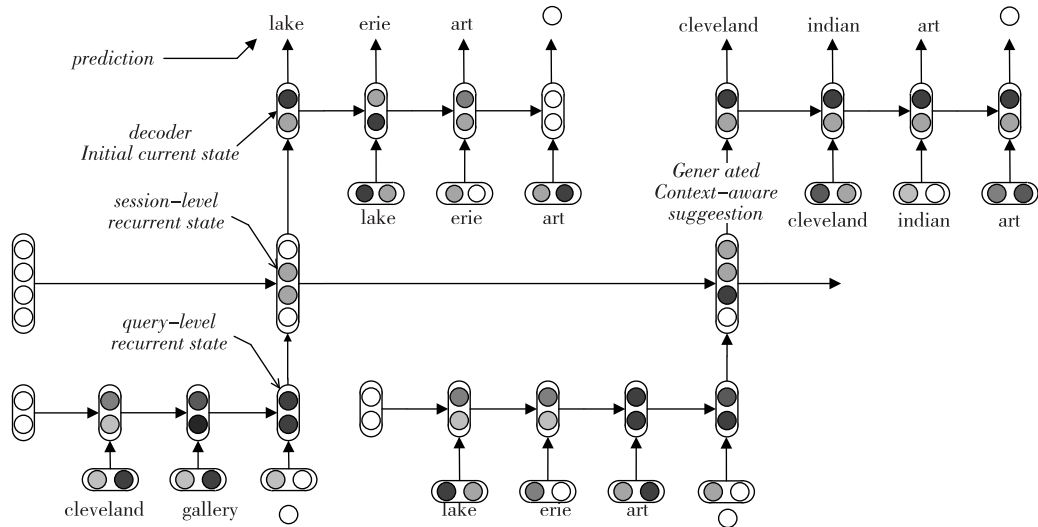


图 9 两层表征的用于建议生成的 HRED 模型^[54]

Fig. 9 Two-level hierarchy representative of HRED for suggestion^[54]

3) 最大化互信息模型(MMI)

Seq2Seq 虽然在短对话上具有良好的效果,但是由于其在预测过程中使用极大似然估计(Maximum Likelihood Estimate, MLE),使得其在对话多样性上的表现效果不佳,模型更倾向于产生语法上合理而非正确性最佳的“稳妥”回复.针对这个缺陷,文献[57]提出了最大化互信息模型(Maximum Mutual Information, MMI).

MMI 模型中提出了利用互信息作为输出多样性的衡量标准,并提出了 MMI-bidi 的优化目标函数:

$$\hat{T} = \arg \max_T \{ (1 - \lambda) \log p(T | S) + \lambda \log p(S | T) - \lambda \log p(S) \} = \arg \max_T \{ (1 - \lambda) \log p(TS) + \lambda \log p(ST) \}, \quad (4)$$

其中 S 代表源信息, T 代表目标信息(即系统产生的回复), λ 为常量.可以看出 MMI 模型的优化目标不仅是最大化从源信息产生目标信息的概率,同时也加入了从预测的回应生成相应的源信息的最大化目标,从而提高了信息和回答之间的相互关系,有效降低了对话系统生成的回复中无意义的“稳妥”回复的概率.

4) 注意力模型

注意力机制并不是一个全新的概念,2014 年 Bahdanau 等^[58]就提出了注意力的概念.注意力机制来源于人类观察环境的习惯规律,模拟人类在观察事物时,大脑往往只关注重要的局部,获取需要的信息的过程.2017 年,谷歌提出了一种基于注意力机制的 Transformer 模型(如图 10 所示)作为替代传统 CNN 和 RNN 结构的新思路^[59],注意力机制开始在

各个领域被广泛应用.

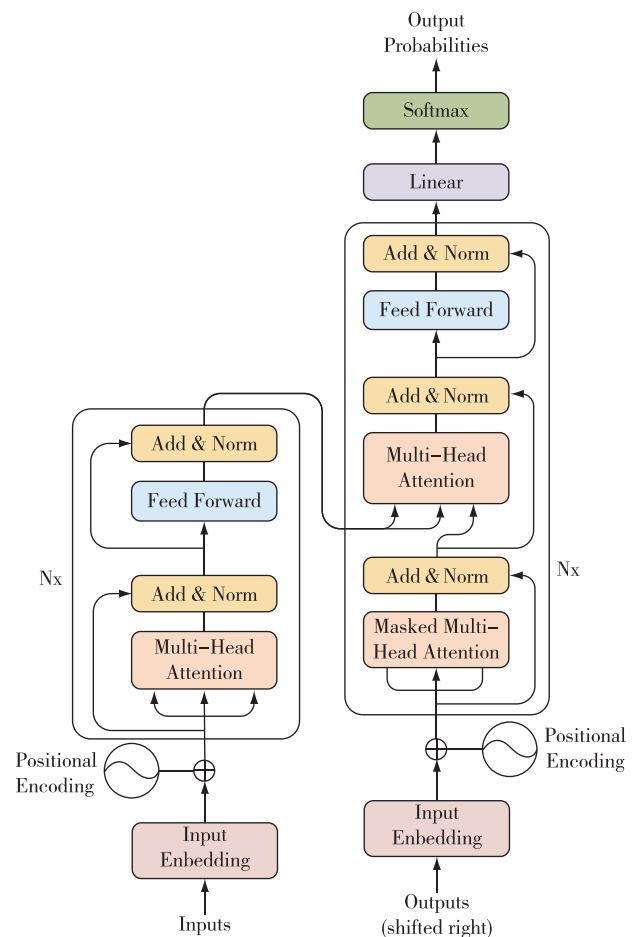


图 10 Transformer 模型结构^[59]

Fig. 10 The Transformer model architecture^[59]

将注意力机制运用到对话生成模型中,主要是为了解决 Seq2Seq 对长句子理解力较差的问题.正如之前在 HRED 模型中所讨论的那样,Seq2Seq 在短句文本生成上的表现比较优秀,但是在长句子或者多轮对话上表现效果不佳.使用 HRED 的多层次方法可以有效解决多轮对话上表现不佳的问题,但是对于 Seq2Seq 的生成效果提升相对较小.因而引入注意力机制,使解码器对于源序列中的信息选择重点后进行动态记忆,从而提升长句子的生成质量.引入注意力机制的对话生成模型如图 11 所示.

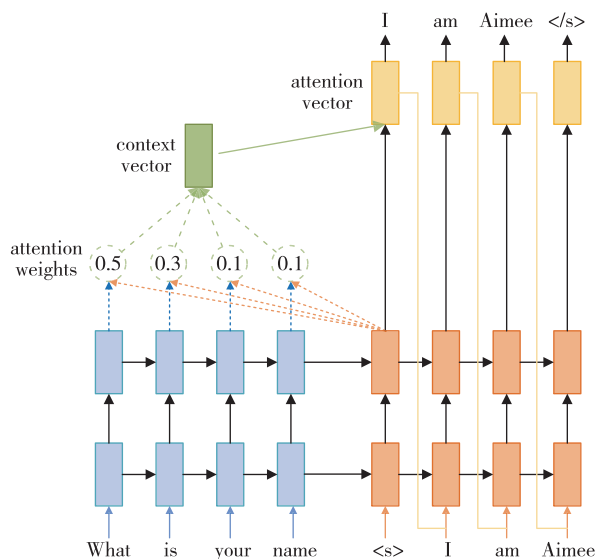


图 11 引入注意力机制的对话生成模型^[60]

Fig. 11 An example of dialogue generation model with attention model^[60]

首先计算源输入序列的注意力权重,注意力权

重通过当前的目标隐藏层状态和所有的源序列的状态互相比较得出:

$$\alpha_{ts} = \frac{\exp(\text{score}(h_t, \bar{h}_s))}{\sum_{s'=1}^S \exp(\text{score}(h_t, \bar{h}_{s'}))} \quad (5)$$

h_t 为当前的目标隐藏层状态, $h_s, h_{s'}$ 均为源序列的隐藏层状态, score 为评分计算函数.函数将每一个源输入序列的隐层状态和目标序列的隐层状态进行比较,输出一个标准化的评分结果,得到注意力权重表示后,计算源序列的权重均值,作为上下文向量 c_t :

$$c_t = \sum_s \alpha_{ts} \bar{h}_s \quad (6)$$

其中 α_{ts} 为目标输入的注意力权重.最终将上下文向量和当前目标序列的隐藏层状态互相结合生成得到注意力向量 a_t ,并将注意力向量作为下一个时刻的初始状态输入到生成模型中:

$$a_t = f(c_t, h_t) = \tanh(W_c [c_t, h_t]) \quad (7)$$

其中 W_c 为需要学习的模型参数.

5) 强化学习生成模型

尽管 Seq2Seq 及其改进模型在多个任务上均取得了不错的效果,但很多情况下,对这类模型的训练均面临着使用的语料集不够庞大或者标记缺失的问题,而且单纯以损失函数作为优化目标的方法有时并不能准确体现对话系统在多方面的确切质量,在对话系统产生一个质量较为糟糕的回复之后,后续的对话质量也会受到影响.文献[44]另辟蹊径提出了利用强化学习进行对话策略的学习的方法,使用如图 12 所示的结构模拟两个代理之间的对话过程,利用强化学习能着眼长远学习最优策略的特点,解

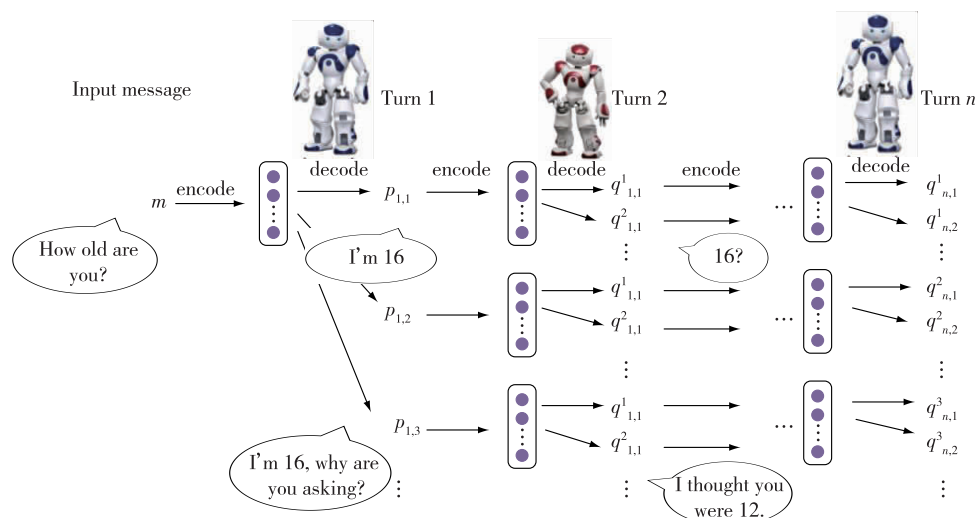


图 12 两个代理之间的对话模拟过程^[44]

Fig. 12 Dialogue simulation between the two agents^[44]

决了 Seq2Seq “短视” 的问题,同时提升了生成回复的多样性,减少了训练过程中对于训练语料集的庞大需求.

工作中利用模拟 2 个 agent 的对话过程来进行模型的学习,使用策略梯度方法 (policy gradient methods)^[61] 通过最大化期望奖励来优化模型参数.在奖励函数的定义上,同时考虑了多样性、相关性和生成回复的应答难易程度,综合优化模型的表现效果.

$$r(a, [p_i, q_i]) = \lambda_1 r_1 + \lambda_2 r_2 + \lambda_3 r_3, \quad (8)$$

其中 $[p_i, q_i]$ 表示 2 个 agent 的一轮对话, r_1, r_2, r_3 分别表示 3 种评价指标对应定义的奖励函数.系统从长远角度学习最大化收益的方法,工作中还使用了互信息指标作为相关性的评价标准,进一步提升模型的训练效果.自动评测和人工评测综合评价的结果表明,模型生成的对话结果在质量上有了显著提升.

2 质量评价标准

相较于机器翻译、文本摘要等其他的自然语言处理任务已经具备一些较为成熟的自动化评价标准,如何评价对话系统,一直是对话系统的研究的重点和难题之一.如图 13 所示为其中一种从系统、对话和内容层面划分的综合评价标准 (<https://zhuanlan.zhihu.com/p/33088748>).对话系统的评价指标的设计需要涉及多个角度,尤其是非任务型对话系统更是难以通过某一固定的评价标准来进行衡量^[62].本部分介绍一些对话系统中常用的评价指标.

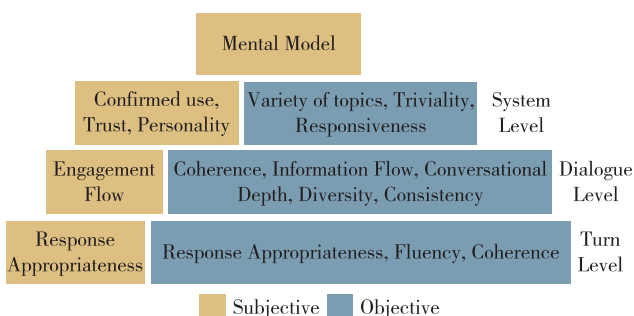


图 13 不同层次的对话系统评价关注点

Fig. 13 Different focus points on different layers of the dialogue system evaluation

2.1 PARADISE

1997 年, Walker 等^[63] 提出了一个将对话持续时

间及其他特征融入线性方程的评价系统 PARADISE, 利用对用户的满意度的刻画来进行对任务型对话系统的评价. 该方法使用一个标注有用户满意度的数据集和一个包含客观评价的数据集通过线性回归的方法获得一个权重指标用来描述用户满意度. 对话的成功率、对话时长、系统补充询问次数等因素都将影响到这个评价系统的评价结果. 基于这个方法对于多种评价角度的考虑, 在对话策略的学习中同样也可以采用这种方式作为优化目标^[64].

但是, 实际的人机交互中, 关于任务的完成与否的判断指标还是比较模糊的, 因为任务的完成与否实际上是难以单纯使用“是”或“否”来进行定义的, 因而 PARADISE 虽然考虑因素非常丰富, 但是实际评价效果往往差强人意甚至和人工评价结果存在严重误差^[65].

2.2 词重叠类评价

作为自然语言处理领域的几个经典的衡量指标, BLEU、METERO 和 ROUGE 这几种词重叠类评价指标也常常被用于对话系统的效果评估指标上.

BLEU 由 IBM 在 2002 年提出, 通过比较模型的生成语句和参考答案语句中的 n 元词组在整个训练语料中共现次数来对生成结果做出评价^[66]. 该方法认为如果共现次数越多, 则生成结果越准确, 效果越好.

$$I_{BLEU} = \mu_{BP} \cdot \exp\left(\sum_{n=1}^N w_n \log P_n\right), \quad (9)$$

其中 P_n 为 n 元短语词组在整个数据集中的准确度, w_n 表示各个 n 元短语词组的权重, μ_{BP} 是长度过短惩罚因子.

ROGUE 包含 ROUGE-N、ROUGE-L (最长公共子句, F-measure)、ROUGE-W (带权重的最长公共子句, F-measure)、ROUGE-S (不连续二元组, F-measure) 4 种, 主要用于文本摘要领域的评价^[67]. 以 ROGUE-L 为例, 通过记录信息与生成之间的最长公共子序列长度并计算 F-measure 分数来评价效果.

METEOR 则是基于 BLEU 的改进方法, 使用 WordNet 计算特定的序列匹配、同义词、词根和词缀、释义之间的匹配关系, 改善了 BLEU 的效果, 使其跟人工判别有更强的相关性^[68]. 很明显, 这些基于单一的语义指标进行衡量的方式很难对对话系统的生成结果做出有效可行的评估.

2.3 词向量评价

词重叠指标直接通过比较生成结果和真实响应

中的信息重合程度作为评价标准,效果缺乏可行性,词向量评价指标改进了这一方法,它通过 Word2Vec、Sent2Vec^[69] 等方法将句子转换为向量表征,然后和真实响应的相应表征进行比较,以获得两者之间的相似程度.通过词向量表征,生成的回复的多样性得到了有效的提高.

词向量评价指标主要包括 Greedy Matching^[70]、Embedding Average^[71-73]、Vector Extrema^[74] 等方法,通过寻找生成结果和真实响应之间的高相似度词语或者直接比较两者之间的句子级别的语义相似度作为评价指标.

2.4 人工评价

在文献[44]中,作者提出了使用自动评价和人工评价相结合的方式对对话结果进行评价的方法,并定义了利用“对话长度+对话生成结果的多样性”作为自动评价的指标.在人工评价上,通过统计3名评价人员对随机抽取的500个对话样本中的多种不同答案的优劣排名来表示生成效果的好坏.图14展示了人工评估下的评测结果,3列分别代表强化学习对话系统对话被判为最优、最劣和持平的情况.

| Setting | RL-win | RL-lose | Tie |
|-----------------------------|--------|---------|------|
| single-turn general quality | 0.40 | 0.36 | 0.24 |
| single-turn ease to answer | 0.52 | 0.23 | 0.25 |
| multi-turn general quality | 0.72 | 0.12 | 0.16 |

图14 强化学习方法在人工评估下的结果^[44]

Fig. 14 RL gains based on pairwise human judgments^[44]

人工评价指标主要包含两方面,一方面是对自动评价指标的人为定义,另一方面是通过人工主观评价对对话系统的质量做出评判.在近期的一些工作中,部分研究人员提出了自定义的评价指标,这种评价指标的优势就是能更有针对性地对对话生成效果做出评价,但是相对应的劣势也非常明显,评价指标的公平性难以确保,而且评价效果也严重依赖于所选取的数据集^[75-76].人工主观评价系统的优势在于评价更为全面,更能接近真实的评估效果.然而,人工评价不可避免地存在主观性问题,评估人员能否代表所有用户存在一定的问题,且需要雇佣足够的测评人员,很明显这需要大量的开销.通过外包模式进行评估以及借助网络进行实时评估等方法都可以对这个问题有所帮助.

3 总结与展望

本文从不同的对话任务着手,对各类基于多轮交互的人机对话系统中的主要学习方法进行了讨论,深度学习方法的引入也使得人机对话系统的效果和拓展性得到了显著的提升,使人机对话系统得以走入商用.而如何将多种学习方法有机地结合,以更好地提升对话系统的生成质量,也将成为这个课题下值得研究的问题之一.针对多轮交互人机对话系统的研究现状,我们还可以在以下方面深入探索:

1) 不论是任务型还是非任务型对话系统,当前的研究成果已经在这些方面上取得不错的成绩.然而在实际场景下,对话系统的弱点往往在几轮对话后就会暴露.如何利用持续稳定的个性化模型来赋能对话系统,优化对话系统的交互效果成为了一个重要的研究方向.

2) 知识图谱(Knowledge Graph)作为近期的另一热门研究方向受到了大量关注,“知识图谱+”的方法也被广泛应用到了大量的研究领域.将知识图谱作为外部知识库引入多轮对话系统,能极大地提升对话系统的准确性和流畅度^[77],但如何有效地结合知识图谱和多轮对话系统亟待探索.

3) 多轮对话系统的评价标注目前还处于探讨之中,如何采用合适的标准完成自动化的对话质量评估不但对准确衡量模型效果有帮助,也能有效指导对话系统的学习策略的发展方向.

总之,多轮交互的人机对话系统作为自然语言处理中最具挑战性的重大问题之一,在近期也是众多研究工作聚焦的热点课题,对于多轮人机对话系统的研究还有很大的空间可供研究人员探索.

参考文献

References

- [1] López-Cózar R, Callejas Z, Griol D, et al. Review of spoken dialogue systems[J]. *Loquens*, 2014, 1(2): 012
- [2] Weizenbaum J. ELIZA: a computer program for the study of natural language communication between man and machine[J]. *Communications of the ACM*, 1966, 9(1): 36-45
- [3] Zhou L, Gao J, Li D, et al. The design and implementation of xiaoIce, an empathetic social chatbot [J]. *ArXiv Preprint ArXiv:1812.08989*, 2018
- [4] Zhu H Y, Chen E H, Liu Q, et al. XiaoIce band[C] // *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining-KDD '18*, July 17-August 23, 2018. London, United Kingdom. New York, USA: ACM Press, 2018

- [5] Bellegarda J R. Spoken language understanding for natural interaction: the siri experience [M] // *Natural Interaction with Robots, Knowbots and Smartphones*. New York, NY: Springer New York, 2013: 3-14. DOI: 10.1007/978-1-4614-8280-2_1
- [6] Mikolov T, Chen K, Corrado G, et al. Efficient estimation of word representations in vector space [J]. *ArXiv Preprint ArXiv:1301.3781*, 2013
- [7] Mikolov T, Sutskever I, Chen K, et al. Distributed representations of words and phrases and their compositionality [C] // *Advances in Neural Information Processing Systems*, 2013: 3111-3119
- [8] Martin J H, Jurafsky D. *Speech and language processing: an introduction to natural language processing, computational linguistics, and speech recognition* [M]. Upper Saddle River: Pearson/Prentice Hall, 2009
- [9] Mo K, Zhang Y, Li S, et al. Personalizing a dialogue system with transfer reinforcement learning [C] // *Thirty-Second AAAI Conference on Artificial Intelligence*, 2018
- [10] Li X, Chen Y N, Li L, et al. End-to-end task-completion neural dialogue systems [J]. *ArXiv Preprint ArXiv:1703.01008*, 2017
- [11] Hakkani-Tür D, Tur G, Celikyilmaz A, et al. Multi-domain joint semantic frame parsing using Bi-directional RNN-LSTM [C] // *Interspeech 2016, ISCA, 2016: 715-719*
- [12] Ravuri S, Stolcke A. Recurrent neural network and lstm models for lexical utterance classification [C] // *Sixteenth Annual Conference of the International Speech Communication Association*, 2015.
- [13] Hashemi H B, Asiaee A, Kraft R. Query intent detection using convolutional neural networks [C] // *International Conference on Web Search and Data Mining, Workshop on Query Understanding*, 2016.
- [14] Shen Y L, He X D, Gao J F, et al. Learning semantic representations using convolutional neural networks for web search [C] // *Proceedings of the 23rd International Conference on World Wide Web-WWW '14 Companion*, April 7-11, 2014. Seoul, Korea. New York, USA: ACM Press, 2014: 373-374
- [15] Deng L, Tur G, He X D, et al. Use of kernel deep convex networks and end-to-end learning for spoken language understanding [C] // *2012 IEEE Spoken Language Technology Workshop (SLT)*, December 2-5, 2012. Miami, FL, USA. New York, USA: IEEE, 2012: 210-215
- [16] Tur G, Deng L, Hakkani-Tur D, et al. Towards deeper understanding: deep convex networks for semantic utterance classification [C] // *2012 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, March 25-30, 2012. Kyoto, Japan. New York, USA: IEEE, 2012: 5045-5048
- [17] Deoras A, Sarikaya R. Deep belief network based semantic taggers for spoken language understanding [C] // *Interspeech*, 2013: 2713-2717
- [18] Ramshaw L A, Marcus M P. *Text chunking using transformation-based learning* [M] // *Text, Speech and Language Technology*. Dordrecht: Springer Netherlands, 1999: 157-176. DOI: 10.1007/978-94-017-2390-9_10
- [19] Mesnil G, He X, Deng L, et al. Investigation of recurrent-neural-network architectures and learning methods for spoken language understanding [C] // *Interspeech*, 2013: 3771-3775
- [20] Yao K, Zweig G, Hwang M Y, et al. Recurrent neural networks for language understanding [C] // *Interspeech*, 2013: 2524-2528
- [21] Henderson M. Machine learning for dialog state tracking: a review [C] // *Proceedings of The First International Workshop on Machine Learning in Spoken Language Processing*, 2015
- [22] Henderson M, Thomson B, Young S. Deep neural network approach for the dialog state tracking challenge [C] // *Proceedings of the SIGDIAL 2013 Conference*, 2013: 467-471
- [23] Mrkšić N, Séaghdha D O, Thomson B, et al. Multi-domain dialog state tracking using recurrent neural networks [J]. *ArXiv Preprint ArXiv:1506.07190*, 2015
- [24] Lei W Q, Jin X S, Kan M, et al. Sequicity: simplifying task-oriented dialogue systems with single sequence-to-sequence architectures [C] // *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, Melbourne, Australia. Stroudsburg, PA, USA: Association for Computational Linguistics, 2018
- [25] Cuayáhuitl H, Keizer S, Lemon O. Strategic dialogue management via deep reinforcement learning [J]. *ArXiv Preprint ArXiv:1511.08099*, 2015
- [26] Yan Z, Duan N, Chen P, et al. Building task-oriented dialogue systems for online shopping [C] // *Thirty-First AAAI Conference on Artificial Intelligence*, 2017
- [27] Stent A, Marge M, Singhai M. Evaluating evaluation methods for generation in the presence of variation [M] // *Computational Linguistics and Intelligent Text Processing*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2005: 341-351. DOI: 10.1007/978-3-540-30586-6_38
- [28] Walker M A, Stent A, Mairesse F, et al. Individual and domain adaptation in sentence planning for dialogue [J]. *Journal of Artificial Intelligence Research*, 2007, 30: 413-456
- [29] Angeli G, Liang P, Klein D. A simple domain-independent probabilistic approach to generation [C] // *Proceedings of the 2010 Conference on Empirical Methods in Natural Language Processing*. Association for Computational Linguistics, 2010: 502-512
- [30] Wen T, Gasic M, Mrkšić N, et al. Semantically conditioned LSTM-based natural language generation for spoken dialogue systems [C] // *Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing*, Lisbon, Portugal. Stroudsburg, PA, USA: Association for Computational Linguistics, 2015: 1711-1721
- [31] Wen T H, Gasic M, Kim D, et al. Stochastic language generation in dialogue using recurrent neural networks with convolutional sentence reranking [J]. *ArXiv Preprint ArXiv:1508.01755*, 2015
- [32] Wen T H, Gasic M, Mrkšić N, et al. Multi-domain neural network language generation for spoken dialogue systems [J]. *ArXiv Preprint ArXiv:1603.01232*, 2016

- [33] Su S Y, Lo K L, Yeh Y T, et al. Natural language generation by hierarchical decoding with linguistic patterns[J]. ArXiv Preprint ArXiv:1808.02747, 2018
- [34] Lemon O. Learning what to say and how to say it: Joint optimisation of spoken dialogue management and natural language generation[J]. *Computer Speech & Language*, 2011, 25(2):210-221
- [35] Hinton G, Deng L, Yu D, et al. Deep neural networks for acoustic modeling in speech recognition[J]. *IEEE Signal Processing Magazine*, 2012, 29
- [36] Van Den Oord A, Dieleman S, Zen H, et al. Wavenet: a generative model for raw audio[J]. *SSW*, 2016, 125
- [37] Dhingra B, Li L, Li X, et al. Towards end-to-end reinforcement learning of dialogue agents for information access[J]. ArXiv Preprint ArXiv:1609.00777, 2016
- [38] Eric M, Manning C D. Key-value retrieval networks for task-oriented dialogue [J]. ArXiv Preprint ArXiv:1705.05414, 2017
- [39] Sutskever I, Vinyals O, Le Q V. Sequence to sequence learning with neural networks[C]// *Advances in Neural Information Processing Systems*, 2014:3104-3112
- [40] Cho K, Van Merriënboer B, Gulcehre C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[J]. ArXiv Preprint ArXiv:1406.1078, 2014
- [41] Williams J D, Zweig G. End-to-end lstm-based dialog control optimized with supervised and reinforcement learning [J]. ArXiv Preprint ArXiv:1606.01269, 2016
- [42] Braunschweiler N, Papangelis A. Comparison of an end-to-end trainable dialogue system with a modular statistical dialogue system [C]// *Interspeech 2018, ISCA: ISCA*, 2018:576-580
- [43] Ritter A, Cherry C, Dolan W B. Data-driven response generation in social media[C]// *Proceedings of the Conference on Empirical Methods in Natural Language Processing*. Association for Computational Linguistics, 2011:583-593
- [44] Li J, Monroe W, Ritter A, et al. Deep reinforcement learning for dialogue generation [J]. ArXiv Preprint ArXiv:1606.01541, 2016
- [45] Ji Z, Lu Z, Li H. An information retrieval approach to short text conversation [J]. ArXiv Preprint ArXiv:1408.6988, 2014
- [46] Hu B, Lu Z, Li H, et al. Convolutional neural network architectures for matching natural language sentences[C]// *Advances in Neural Information Processing Systems*, 2014:2042-2050
- [47] Wang H, Lu Z, Li H, et al. A dataset for research on short-text conversations [C]// *Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing*, 2013:935-945
- [48] Zhao W X, Jiang J, Weng J S, et al. Comparing twitter and traditional media using topic models[M]// *Lecture Notes in Computer Science*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011:338-349. DOI: 10.1007/978-3-642-20161-5_34
- [49] Lowe R, Pow N, Serban I, et al. The ubuntu dialogue corpus: a large dataset for research in unstructured multi-turn dialogue systems [J]. ArXiv Preprint ArXiv:1506.08909, 2015
- [50] Vinyals O, Le Q. A neural conversational model[J]. ArXiv Preprint ArXiv:1506.05869, 2015
- [51] Khandelwal U, He H, Qi P, et al. Sharp nearby, fuzzy far away: how neural language models use context[J]. ArXiv Preprint ArXiv:1805.04623, 2018
- [52] Yao K, Zweig G, Peng B. Attention with intention for a neural network conversation model [J]. ArXiv Preprint ArXiv:1510.08565, 2015
- [53] Xing C, Wu Y, Wu W, et al. Hierarchical recurrent attention network for response generation[C]// *Thirty-Second AAAI Conference on Artificial Intelligence*, 2018
- [54] Sordoni A, Bengio Y, Vahabi H, et al. A hierarchical recurrent encoder-decoder for generative context-aware query suggestion[C]// *Proceedings of the 24th ACM International Conference on Information and Knowledge Management*. ACM, 2015:553-562
- [55] Hochreiter S. Untersuchungen zu dynamischen neuronalen netzen [J]. *Diploma, Technische Universität München*, 1991, 91(1)
- [56] Serban I V, Sordoni A, Lowe R, et al. A hierarchical latent variable encoder-decoder model for generating dialogues [C]// *Thirty-First AAAI Conference on Artificial Intelligence*, 2017
- [57] Li J, Galley M, Brockett C, et al. A diversity-promoting objective function for neural conversation models [J]. ArXiv Preprint ArXiv:1510.03055, 2015
- [58] Bahdanau D, Cho K, Bengio Y. Neural machine translation by jointly learning to align and translate [J]. ArXiv Preprint ArXiv:1409.0473, 2014
- [59] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need [C]// *Advances in Neural Information Processing Systems*, 2017:5998-6008
- [60] 戴怡琳, 刘功申. 智能聊天机器人的技术综述[J]. *计算机科学与应用*, 2018, 8(6):918-929
- DAI Yilin, LIU Gongshen. Survey of intelligent chatbot technology[J]. *Comput Sci Appl*, 2018, 8(6):918-929
- [61] Williams R J. Simple statistical gradient-following algorithms for connectionist reinforcement learning [J]. *Machine Learning*, 1992, 8(3/4):229-256
- [62] Liu C W, Lowe R, Serban I V, et al. How not to evaluate your dialogue system: an empirical study of unsupervised evaluation metrics for dialogue response generation [J]. ArXiv Preprint ArXiv:1603.08023, 2016
- [63] Walker M A, Litman D J, Kamm C A, et al. PARADISE: a framework for evaluating spoken dialogue agents [J]. ArXiv Preprint Cmp-Lg/9704004, 1997
- [64] Rieser V, Lemon O. Learning and evaluation of dialogue strategies for new applications: empirical methods for optimization from small data sets [J]. *Computational Linguistics*, 2011, 37(1):153-196
- [65] Larsen L B. Issues in the evaluation of spoken dialogue systems using objective and subjective measures [C]// *2003 IEEE Workshop on Automatic Speech Recognition and Understanding (IEEE Cat. No. 03EX721)*. IEEE, 2003:209-214
- [66] 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. Association for Computational Linguistics, 2002: 311-318
- [67] Lin C Y. ROUGE: a package for automatic evaluation of summaries [C] // Text Summarization Branches Out: Proceedings of the ACL-04 Workshop. Barcelona, Spain, 2004: 74-81
- [68] Banerjee S, Lavie A. METEOR: An automatic metric for MT evaluation with improved correlation with human judgments [C] // Proceedings of the Acl Workshop on Intrinsic and Extrinsic Evaluation Measures for Machine Translation and/or Summarization, 2005: 65-72
- [69] Pagliardini M, Gupta P, Jaggi M. Unsupervised learning of sentence embeddings using compositional n-gram features [C] // Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics; Human Language Technologies, Volume 1 (Long Papers), New Orleans, Louisiana. Stroudsburg, PA, USA: Association for Computational Linguistics, 2018
- [70] Rus V, Lintean M. A comparison of greedy and optimal assessment of natural language student input using word-to-word similarity metrics [C] // Proceedings of the Seventh Workshop on Building Educational Applications Using NLP. Association for Computational Linguistics, 2012: 157-162
- [71] Foltz P W, Kintsch W, Landauer T K. The measurement of textual coherence with latent semantic analysis [J]. Discourse Processes, 1998, 25(2/3): 285-307
- [72] Landauer T K, Dumais S T. A solution to Plato's problem: the latent semantic analysis theory of acquisition, induction, and representation of knowledge [J]. Psychological Review, 1997, 104(2): 211-240
- [73] Mitchell J, Lapata M. Vector-based models of semantic composition [J]. Proceedings of ACL-08: HLT, 2008: 236-244
- [74] Forgues G, Pineau J, Larchevêque J M, et al. Bootstrapping dialog systems with word embeddings [C] // Nips, Modern Machine Learning and Natural Language Processing Workshop, 2014
- [75] Sordani 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; Human Language Technologies, Denver, Colorado. Stroudsburg, PA, USA: Association for Computational Linguistics, 2015
- [76] Shang L F, Lu Z D, 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 (Volume 1: Long Papers), Beijing, China. Stroudsburg, PA, USA: Association for Computational Linguistics, 2015
- [77] Liu S, Chen H, Ren Z, et al. Knowledge diffusion for neural dialogue generation [C] // Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers), 2018: 1489-1498

A survey of human-computer dialogue system based on multiple-round interaction

CHEN Jianpeng¹ MA Jianhui¹ WANG Yijun¹

¹ Anhui Province Key Laboratory of Big Data Analysis and Application, University of Science and Technology, Hefei 230027

Abstract In recent years, as one of the important issues in natural language processing, the human-machine dialogue system has received more and more attention. Methods of deep learning based on big data are widely used in dialogue systems. In this paper, the background of human-machine dialogue system is firstly introduced, then dialogue system based on multiple-round interaction is taken as an example. This paper emphasizes on task-oriented and non-task-oriented dialogue systems, elaborates the main types and current research progress. After that, this paper provides an overview of some main methods of evaluating the dialogue system. Finally, based on the current research status, the prospect of some future research directions on human-machine dialogue system are discussed.

Key words human-computer dialogue system; natural language processing; deep learning; artificial intelligence