

基于深度学习的开放领域对话系统研究综述

陈 晨^{1),4)} 朱晴晴¹⁾ 严 睿²⁾ 柳军飞³⁾

¹⁾(北京大学软件与微电子学院 北京 100871)

²⁾(北京大学计算机科学技术研究所 北京 100871)

³⁾(北京大学软件工程国家工程研究中心 北京 100871)

⁴⁾(北京大学网络安全和信息化委员会办公室 北京 100871)

摘 要 人机对话系统能够让机器通过人类语言与人进行交互,是人工智能领域的一项重要工作. 因其在虚拟助手和社交聊天机器人等领域的商业价值而广受工业界和学术界的关注. 近年来,互联网社交数据快速增长促进了数据驱动的开放领域对话系统的研究,尤其是将深度学习技术应用到其中取得了突破性进展. 基于深度学习的开放领域对话系统使用海量社交对话数据,通过检索或者生成的方法建立对话模型学习对话模式. 将深度学习融入检索式系统中研究提高对话匹配模型的效果,将深度学习融入生成式系统中构建更高质量的生成模型,成为了基于深度学习的开放领域对话系统的主要任务. 本文对近几年基于深度学习的开放领域对话系统研究进展进行综述,梳理、比较和分析主要方法,整理其中的关键问题和已有解决方案,总结评测指标,展望未来研究趋势.

关键词 对话系统;聊天机器人;深度学习;序列到序列模型;匹配模型;对话系统评测

中图法分类号 TP18 **DOI号** 10.11897/SP.J.1016.2019.01439

Survey on Deep Learning Based Open Domain Dialogue System

CHEN Chen^{1),4)} ZHU Qing-Qing¹⁾ YAN Rui²⁾ LIU Jun-Fei³⁾

¹⁾(School of Software and Microelectronics, Peking University, Beijing 100871)

²⁾(Institute of Computer Science and Technology, Peking University, Beijing 100871)

³⁾(National Engineering Research Center for Software Engineering (Peking University), Beijing 100871)

⁴⁾(Office of the Cyberspace Affairs Commission of Peking University, Beijing 100871)

Abstract The human-machine dialogue system enables easy interaction interface between humans and computers using natural languages, which is of growing significance in artificial intelligence. Owing to its commercial value in the fields of virtual assistants and social Chatbots, it has been widely concerned by business and academia. Dialogue systems can be classified as domain-specific and open-domain models. Recently, along with the fast prosperity of social media on the internet, research of data-driven open domain dialogue systems has been promoted. In particular, as a major breakthrough, deep learning has proven to be an extremely powerful tool in this field. The deep learning based open domain dialogue system directly constructs a dialogue model from query to reply by applying end-to-end deep learning techniques to processing massive dialogue data. Our paper starts by summarizing the background and follows by introducing the state-of-the-art methods of implementing the open domain dialogue system: retrieval-based, generation-based and the combination of both. Then, we review the methods that can address several critical problems on this domain. After that, the evaluation procedures of the open domain dialogue system are detailed. Finally, we end up with analyzing and forecasting the future

development trend that can bring the dialogue system research into a new frontier.

Keywords dialogue system; Chatbot; deep learning; sequence-to-sequence model; matching model; dialogue system evaluation

1 引 言

让机器具备与人交流的能力是人工智能领域的一项重要工作,同时也是一项极具挑战的任务.1951年图灵在《计算机与智能》一文中提出用人机对话来测试机器智能水平^[1],引起了研究者的广泛关注.此后,学者们尝试了各种方法研究建立对话系统.按照系统建设的目的,对话系统被分为任务驱动的限定领域对话系统 and 无特定任务的开放领域对话系统^[2-3].限定领域对话系统是为了完成特定任务而设计的,例如网站客服、车载助手等.开放领域对话系统也被称为聊天机器人,是无任务驱动、为了纯聊天或者娱乐而开发的,它的目的是生成有意义且相关的回复.

工业界将对话系统视作下一代人机交互的主要形式,近年来投入大量人力到相关研发工作中.对话系统商业应用不断涌现,有不少产品已进入量产阶段.在限定领域对话系统中,以苹果 Siri 和微软 Cortana 为代表的语音助手已通过手机、操作系统等媒介被人们广泛使用;另外,以亚马逊 Echo、百度 Duer、谷歌 Home 和天猫精灵为代表的虚拟助手式智能音箱也已走进千家万户.在开放领域对话系统方面,微软针对不用语种开发了聊天机器人 xiaoice、rinna、Zo、Ruuh 等,使用用户达到数千万.

在学术界,过去很长一段时间关于对话系统的研究主要针对限定领域具体任务开展,是口语对话系统的重要分支^[4-7].这些系统严格定义和限制接收的输入,并针对特定任务设计相应的规则、逻辑和回复语句^[8].虽然这些方法在人机交互上取得了很大的进展,但受手工设定规则等方面的影响,其稳健性、可扩展性和领域适应性都有缺陷,也不适用于开放领域.近年来,随着互联网上社交数据的快速增长,数据驱动的开放领域对话系统逐渐成为了学术界关注的热点,人机对话系统也由服务的角色逐步转变为情感伴侣的角色^[9-12].

近年来,深度学习技术的应用使得开放领域对话系统取得了突破性进展,但由于研究时间短、新的

研究成果不断出现,已有的综述都未能全面而深入进行总结.Chen 等人^[3]针对所有对话系统进行综述,但是基于深度学习的开放领域对话系统仅为其中的一部分,无论是模型还是关键问题都未能进行深入描述和分析.张伟男等人^[13]仅对对话系统的评价方法进行综述.Yan^[2]对基于深度学习的开放领域对话系统进行综述,但是受篇幅限制未能从深度学习模型的角度进行详细地分类整理.本文以开放领域对话系统为研究对象,对基于深度学习的实现方法进行全面的回顾和分析,并详尽梳理开放领域对话系统中的关键性问题及解决方案,整理评价指标,廓清本领域的发展状况,展望发展方向,为未来的研究工作奠定基础.

1.1 问题描述

本文的研究对象是开放领域的对话系统,首先将其形式化描述为:在历史对话信息背景下,人将无领域限制的话语作为查询(也可称为消息或问题等)输入计算机,计算机返回对应的回复语句(也可称为响应或回答).以场景设置为标准,对话系统可以分为单轮对话系统和多轮对话系统.单轮对话系统将对话问题简化,只考虑找到给定查询的回复.多轮对话系统需要综合考虑对话上下文(包括历史对话信息和查询),建立对话的长期依赖关系,给出更加符合对话逻辑的回复.

假设 q 表示作为查询的话语, r 表示回复话语, c 代表历史对话信息,

- (1)单轮对话:以 q 为前提,得到语句 r 作为回复;
- (2)多轮对话:在 c 的背景下,以 q 为前提,得到语句 r 作为回复.

表 1 给出中英文对话示例.

表 1 中英文对话示例	
中文	英语
你今天好吗?	How are you today?
不错啊,你呢?	Not bad. How about you?
我很好.	Pretty good.
那太好了.	That is great.

1.2 数据收集

传统的基于规则/模板的开放领域对话系统^[8]

需要手工制定规则,不需要大规模训练集,而数据驱动的方法需要收集大量的对话数据。目前,互联网上已经有大量记录人类交流的数据,其中的大部分数据在经过预处理后,都可以被用到开放领域对话系统的训练中。Luong 等人^[14]将对话数据分成人机对话和人人对话。现有的人机对话语料库主要是面向任务的对话。本文主要针对开放领域对话,所以接下来主要梳理人人对话数据资源。

人人对话数据可以进一步分为口语对话和书面对话:

(1) 口语对话。口语对话具有通俗、口语化特点,说话者通常用对方的思路和方式讲话,倾向于使用较短的单词和短语。其中比较有代表性的数据集包括 Switchboard 电话对话数据集^[15]、DSTC4-5 的 skype 通信数据集^[16-17]、康奈尔电影对话语料库^[18]、OpenSubtitles 网站^①上的 OpenSubtitles 数据集^[19];

(2) 书面对话。书面对话在书面交流中产生,它的特点是用户可以在发送消息前反思他们正在写的东西。书面对话语料可以进一步从来源进行区分,例如文献[20-22]从 Twitter^② 网站上搜集数据构造对话语料。Shang 等人^[12]从新浪微博^③网站上搜集对话语料进行实验。文献[23-24]从聊天软件中收集关于 Ubuntu 使用中遇到的问题和相关回答。Song 等人^[25]从豆瓣论坛^④中收集发帖和回复。

相比其他来源的语料,社交网站的对话数据容易获取,使用者更多。但是这些数据存在不足,常常包含拼写错误、缩略语等,还可能包含口语对话中不会出现的场景表述。例如,用户可能会写“再见并离开”,而不是像口语表述时简单的说“再见”^[10]。另外,社交网站的书面对话还包含近期热门事件或者固定使用的标签,如果不具备相关知识库,计算机将很难理解。

1.3 本文框架

本文第 2 节概述相关深度学习技术;第 3 节介绍基于深度学习的开放领域对话系统主要方法;第 4 节梳理基于深度学习的开放领域对话系统关键问题;第 5 节分类介绍开放领域对话系统的评测方法;第 6 节展望基于深度学习的开放领域对话系统的未来研究趋势;第 7 节是总结。

2 深度学习技术

深度学习是机器学习的分支,是试图使用包含

复杂结构或由多重非线性变换构成的多处理层计算模型对数据进行高层抽象的一类算法。深度学习技术已被广泛应用到图像处理、语音处理、自然语言处理等多个领域,取得了重大突破^[26]。

2.1 神经网络语言模型

语言模型(Language Model, LM)把语料库当作一个随机变量,对给定前面的词语预测下一个词语的任务建模来计算句子概率。神经网络语言模型(Neural Network Language Model, NNLM)最早由 Bengio 等人^[27]提出,其核心思路是用一个 K 维的向量来表示词语,被称为词向量(Word Embedding),使得语义相似的词在向量空间中处于相近的位置,并基于神经网络模型将输入的上下文词向量序列转换成固定长度的上下文隐藏向量,使得语言模型不必存储所有不同词语的排列组合信息,从而改进传统语言模型受词典规模限制的不足。如图 1 所示。




图 1 神经网络语言模型示意图

2.2 自编码器

自编码器(Autoencoder, AE)是一种无监督的学习模型,由 Rumelhart 等人^[28]最早提出。自编码器由编码器和解码器两部分组成,先用编码器对输入数据进行压缩,将高维数据映射到低维空间,再用解码器解压缩,对输入数据进行还原,从而来实现输入到输出的复现。如图 2 所示,自编码器的训练目标是,使得输出 $\hat{X}$ 尽可能地还原输入 X 。其中,编码器和解码器基于神经网络构建。




图 2 自编码器结构示意图

① <http://www.opensubtitles.org>
② <http://twitter.com>
③ <http://weibo.com>
④ <http://www.douban.com>

为了改进基本模型中容易陷入局部最优的情况,深度自编码器模型被提出^[29-30].其中,变分自编码器和条件变分自编码器被用到开放领域的对话系统中,对回复生成的多样性进行控制,示意图如图 3.变分自编码器^[31](Variational Auto-Encoder, VAE)是一种生成模型,它引入统计思想在基础的自编码器模型基础上加入正则约束项,使得隐藏层 z 满足某个分布,并从 z 中自动生成数据.条件变分自编码器^[31](Conditional Variational Auto-Encoders, CVAE)是在变分自编码器之上再加一些额外信息为条件的一类模型.其模型训练和测试时候均以该额外信息 c 为条件.




图 3 变分自编码器(上)和条件变分自编码器(下)模型示意图

2.3 卷积神经网络

卷积神经网络(Convolutional Neural Network, CNN)是人工神经网络的一种.其核心思想是设计局部特征抽取器运用到全局,利用空间相对关系共享参数,来提高训练性能.早期主要运用于图像处理领域,后来被应用到自然语言处理中^[32-33].

卷积层和池化层是卷积神经网络的重要组成部分.其中,卷积层的作用是从固定大小的窗口中读取输入层数据,经过卷积计算,实现特征提取.卷积神经网络在同一层共享卷积计算模型来控制参数规模,降低模型复杂度.池化层的作用是对特征信号进行抽象,用于缩减输入数据的规模,按一定方法将特征压缩.池化的方法包括加和池化、最大池化、均值池化、最小值池化和随机池化.最后一个池化层通常连接到全连接层,来计算最终的输出.

不同研究中的卷积网络模型会有细微差别.以文本表示为例,卷积神经网络在能从文本中提取隐藏特征,形成低维向量表示.如图 4 所示,模型利用局部特征抽取器通过滑动窗口获取变长序列的隐藏特征,并经过池化得到定长输出.




图 4 卷积神经网络应用示意图

2.4 循环神经网络

循环神经网络(Recurrent Neural Network, RNN)是专门设计用于处理序列数据的神经网络架构,它利用时间相对关系减少参数数目以提高训练性能,已经成功地用于自然语言处理中^[34].

循环神经网络具有自环的网络结构.一个简单的循环神经网络如图 5 所示,左边为压缩表示,右边是按时间展开的表示.其中,自环的网络对前面的信息进行记忆并应用于当前输出的计算中,即当前时刻隐藏层的输入包括输入层变量和上一时刻的隐藏层变量.由于可以无限循环,所以理论上循环神经网络能够对任何长度的序列数据进行处理.循环神经网络在实际应用时有梯度消失等问题.后续研究针对该问题提出带存储单元的循环神经网络长短时记忆网络(Long Short-Term Memory, LSTM)^[35]和门控循环单元(Gated Recurrent Unit, GRU)^[36].




图 5 循环神经网络模型示意图

循环神经网络在开放领域对话系统中可用于文本表示,即将词向量按词语在文本中的顺序逐个输入到网络中,末节点的隐藏向量可以作为该话语的语义向量表示.随着技术的发展,其扩展模型双向循环神经网络(Bi-LSTM)、密集循环神经网络(DenseRNN)等都相继被引入到开放领域对话系统中.

2.5 序列到序列模型

序列到序列(Sequence to Sequence, Seq2Seq)模型在 2014 年被 Cho 和 Sutskever 先后提出,前者将该模型命名为编码器-解码器模型(Encoder-Decoder Model)^[37],后者将其命名为序列到序列模型^[38].两

者有一些细节上的差异,但总体思想基本相同. 具体来说,序列到序列模型就是输入一个序列,输出另一个序列,它是一个通用的框架,适用于各种序列的生成任务. 其基本模型利用两个循环神经网络:一个循环神经网络作为编码器,将输入序列转换成定长的向量,将向量视为输入序列的语义表示;另一个循环神经网络作为解码器,根据输入序列的语义表示生成输出序列,如图 6 所示.




图 6 序列到序列模型示意图

层次序列到序列模型在序列到序列模型基础上定义了多层结构的编码器. 首先,每个句子将其包含的词序列向量表示输入循环神经网络得到该句子的向量表示;然后,每个段落将其包含的句子序列向量表示输入另一个循环神经网络得到该段落向量表示.

2.6 注意力机制

通用的序列到序列模型,只使用到编码器的最终状态来初始化解码器的初始状态,导致编码器无法学习到句子内的长期依赖关系,同时解码器隐藏变量会随着不断预测出的新词,稀释源输入句子的影响. 为了解决这个问题,Bahdanau 等人^[39]提出了注意力机制(Attention Mechanism). 注意力机制可以理解回溯策略. 它在当前解码时刻,将解码器 RNN 前一个时刻的隐藏向量与输入序列关联起来,计算输入的每一步对当前解码的影响程度作为权重,如图 7 所示. 其中,前一时刻隐藏向量和输入序列的关联方式有点乘^[39]、向量级联方法^[14]等. 最后,通过 softmax 函数归一化,得到概率分布权重对输入序列做加权,重点考虑输入数据中对当前解码影响最大的输入词.




图 7 注意力机制模型示意图

随着研究的深入,Vaswani 等人^[40]将注意力机制定义为一个查询到一组键值对的映射过程,并提

出了自注意力机制(Self-Attention),即其中的查询、键、值是同一个句子,减少对外部信息的依赖,捕捉数据内部的相关性. 如图 8 所示,V、K、Q 分别代表值、键、查询,若模型为自注意力则 $V=K=Q$. Vaswani 等人^[40]还提出了多头注意力机制,即分多次计算注意力,在不同的表示子空间学习信息. 多头注意力机制先对输入做划分,依次经过线性变换和点积后再拼接作为输出.




图 8 多头注意力机制模型示意图

2.7 记忆网络

记忆网络(Memory Network)^[41]是指通过在外部存储器模块中存储重要信息来增强神经网络的一类模型. 外部存储器模块具有内容可读写、信息可检索和重用的特点. Sukhbaatar 等人^[42]提出了一个用于问答键值存储的端到端记忆网络架构(End-to-End Memory Networks, MemN2N). 其中外部存储器以键-值对结构存储问答知识,可以检索与输入相关的信息,得到相关度权值,然后获取将对应的值加权求和作为输出. 如图 9 所示.




图 9 端到端记忆网络模型示意图

相对于其他的神经网络模型,记忆网络的外部存储器可以构建具有长期记忆模块(如知识库、历

史对话信息等)来增强神经模型。

2.8 生成对抗网络

生成对抗网络(Generative Adversarial Networks, GAN)^[43]是 Goodfellow 等人于 2014 年提出的一种深度学习模型。它包含两个模块:生成模型和判别模型。生成模型的训练目标是生成与训练集中真实数据相似的数据。判别模型是一个二分类器,用来判断这个样本是真实训练样本,还是生成模型生成的样本,其训练目标是尽可能地区分真实数据和生成数据。如图 10 所示, G 代表生成模型, D 代表判别模型。




图 10 生成对抗网络模型示意图

GAN 最早被用在图像处理领域,后来也被用到自然语言处理领域中。与图灵测试的思想类似,在开放领域对话系统中使用生成对抗网络的目标是生成与人类回复无差别的回复。

2.9 强化学习

机器学习按学习范式可以分为有监督学习、无监督学习和强化学习。强化学习(Reinforcement Learning)^[44]是指智能体通过和环境交互,序列化地做出决策和采取动作,并获得奖赏指导行为的学习机制。

经典的强化学习建模框架如图 11 所示:在每个时刻 t ,智能体接收一个观察值 o_t ,收到一个奖励值 r_t ,并执行一个动作 a_t ;从环境的角度,它接收智能体动作 a_t ,给出下一个时刻观察值 o_{t+1} 及对应的奖赏 r_{t+1} 。由此,观察值、动作和奖赏一起构成的序列就是智能体获得的经验数据,智能体的目标则是依据经验获取最大累计奖励。




图 11 强化学习系统模型示意图

近年,深度强化学习的诞生打破早期强化学习模型不稳定难收敛的瓶颈,在人机博弈、无人驾驶、视频游戏等很多任务上取得很好的效果。深度强化

学习的发展主要有两种路线:一种是以 DQN(Deep Q-Learning)^[45]为代表的算法;另一种是策略梯度方法(Policy Gradient Methods)^[46]。策略梯度方法通过梯度下降来学习预期奖励的策略参数,将策略搜索转化成优化问题,并根据目标函数最优值确定最优策略。相比而言,策略梯度方法更适合在自然语言处理领域应用。

3 基于深度学习的开放领域对话系统

基于深度学习的开放领域对话系统以大规模对话语料库作为训练语料,利用深度学习算法学习对话模式。

本文通过调研,将基于深度学习的开放领域对话系统的描绘如图 12 分类。除了按输入是否考虑历史对话信息分为单轮对话系统和多轮对话系统,还可以根据构建方法可分为检索式、生成式和检索与生成相结合的方法:




图 12 基于深度学习的开放领域对话框架示意图

(1) 检索式方法。检索式方法首先构建一个供检索的对话语料库,将用户输入的话语视为对该索引系统的查询,从中选择一个回复。具体来说,当用户在线输入话语后,系统首先检索并初步召回一批候选回复列表,再根据对话匹配模型对候选列表做重排序并输出最佳回复。该方法重点在于让匹配模型克服查询和回复之间的语义差异。流程框架如图 13。




图 13 基于检索式方法的对话系统示意图

(2) 生成式方法。受到神经机器翻译的启发,生成式方法的对话系统首先收集大规模对话语料作为

训练数据,基于深度神经网络构建端到端的对话模型,来学习输入与回复之间的对应模式.在预测阶段,系统根据对话模型计算输入语义向量,再逐个生成词语组成回复话语.

(3)检索与生成相结合的方法.还有一些系统不限于使用单一方法,而是将检索式和生成式方法相结合构造开放领域对话系统.

本节对深度学习在每类方法中的应用情况进行详细整理和分析比较.

3.1 深度学习在单轮检索模型的应用

基于检索方法的开放领域单轮对话系统与基于

检索方法的问答系统类似,对用户输入的查询先检索再重排序给出最佳回复.单轮检索模型的核心步骤是构建查询-回复的匹配模型,其中包含语义表示模型和语义融合模型.语义表示模型将查询和回复映射到语义向量;语义融合模型是对查询语义向量和回复语义向量融合过程建模.将深度学习引入到匹配模型中,可以增强匹配模型中语义表示和语义融合计算的能力. Guo 等人^[47]将匹配模型分为以表示为中心和以融合为中心.本文发现还有一类系统同时建立表示和融合为中心的匹配模型,最后结合两者来计算匹配分数.相关文献分类整理如表 2.

表 2 深度学习在单轮检索模型的应用

分类	文献	深度学习模型
以表示为中心的框架	Shen 等人 ^[48] , Hu 等人 ^[32]	卷积神经网络
	Wan 等人 ^[49]	循环神经网络
	Tan 等人 ^[50]	循环神经网络、卷积神经网络、注意力机制
	Yin 等人 ^[51]	卷积神经网络、注意力机制
	Kim 等人 ^[52]	循环神经网络、注意力机制、自编码器
以融合为中心的框架	Lu 等人 ^[53]	深度神经网络
	Hu 等人 ^[32] , Pang 等人 ^[54]	卷积神经网络
	Liu 等人 ^[55]	循环神经网络、记忆网络
	Wang 等人 ^[56]	循环神经网络、注意力机制
	Wan 等人 ^[57]	空间递归神经网络
表示与融合相结合的框架	Mitra 等人 ^[58] , Yu 等人 ^[59]	卷积神经网络

3.1.1 以表示为中心的框架

在表示为单轮检索对话中,深度学习技术被用于构建文本的语义表示模型,目的是基于查询和回复的词向量矩阵输入捕捉句子隐含语义空间的特征信息.框架如图 14 所示,其中 q 和 r 分别表示查询和回复, s 表示匹配分数.




图 14 以表示为中心的单轮检索模型框架示意图

基于卷积神经网络. Shen 等人^[48]基于卷积神经网络将查询和候选回复的词向量输入通过卷积、池化操作,得到其定长的语义表示向量,再使用余弦相似度函数衡量查询和回复的匹配度.与之类似, Hu 等人^[32]提出的 ARC-I 模型将查询和候选回复

输入到卷积神经网络中计算出语义表示向量,然后用多层感知器(Multi-Layer Perception, MLP)计算匹配分数.

基于循环神经网络. Wan 等人^[49]采用 Bi-LSTM 计算句子表示向量.其主要思想是,双向 LSTM 的隐藏向量序列可以从不同位置表示该的句子语义,使得语义融合过程考察不同位置语境下语义表示的匹配,从而实现多位置匹配分数计算.作者在语义融合时共使用了三种相似度计算算法:余弦值相似度函数、双线性(Bilinear)和带张量参数的算法.最终匹配分数计算是从匹配矩阵中挑选 K 个最大的特征,再经 MLP 进行维度压缩得到.

基于循环神经网络+卷积神经网络/注意力机制. Tan 等人^[50]针对查询-回复匹配任务的提出四种基于 LSTM 的语义表示模型:(1) QA-LSTM. 将查询和回复分别输入 Bi-LSTM 后,再经过池化得到二者的表示向量;(2) Convolutional-pooling LSTM. 将查询和回复分别输入 Bi-LSTM 后,再经过 CNN 模型得到二者的表示向量;(3) Convolution-based LSTMs. 将查询和回复先经过 CNN 计算,然后输入 Bi-LSTM 模型,再经过池化得到表示向量;(4) Attentive LSTMs. 先将查询和回复输入 Bi-

LSTM,并用池化方法先计算查询的语义表示向量,再利用注意力模型根据查询表示向量计算回复的表示向量,使得回复的向量表示包含更多与查询相关的信息量.上述四个模型中,Attentive LSTMs 模型效果最好,其模型示意图如图 15 所示.




图 15 Tan 等人^[50]提出的 Attentive LSTMs 模型示意图

基于卷积神经网络+注意力机制. Yin 等人^[51]提出的 ABCNN 系列模型在用卷积神经网络进行语义表示后,再使用注意力机制基于一个句子表示来获得另外一个句子的表示,拓展表示信息.他们共提出三种模型:(1) ABCNN-1. 在卷积前计算句子间注意力权重矩阵,然后与原句子矩阵相乘得到其注意力特征映射的矩阵,将这两个矩阵都传给卷积

层;(2) ABCNN-2. 在池化层前采用与 ABCNN-1 类似的方法,基于原句子矩阵计算含注意力特征的矩阵,再将两个矩阵输入给池化层;(3) ABCNN-3. 将 ABCNN-1 和 ABCNN-2 叠加,即卷积和池化前都增加句子间注意力特征矩阵作为输入.

基于循环神经网络+注意力机制+自编码器. Kim 等人^[52]受到 DenseNet^[60]的启发提出基于 DenseRNN 的通用框架匹配模型 DRCN. 如图 16 所示,DRCN 模型包含多层 RNN+Attention 结构,其中每层 RNN 的输入都是前面所有层输出的并集,每层 RNN 的输出向量又都被直接传给语义融合前的池化层作为输入.总的来说,该模型中句子语义表示采用冗余的密集连接方式,整合所有 RNN+Attention 层的输出,相当于每层输出都直接连接到损失函数,可以缓解模型层数增加带来的梯度消失问题.DRCN 模型在合并输入时采用拼接的方法将前面层输入和当前层包含注意力特征的表示向量相结合.由于拼接操作会导致特征向量维度不断增加,DRCN 模型还采用自编码器算法对输入降维,每次将固定长度的向量传递给下一层,同时还起到了正则化的作用.




图 16 Kim 等人^[52]提出的 DRCN 模型示意图

3.1.2 以融合为中心的框架

以融合为中心的单轮检索对话用深度学习方法对回复和查询语义融合过程建模,着力捕捉回复和查询之间的语义融合信息,框架示意图如图 17 所示.

基于深度神经网络. Lu 和 Li^[53]最早使用深度神经网络应实现以融合为中心的 DeepMatch 匹配模型.其方法核心是,用语料预训练不同抽象层级的话题模型,并根据这些话题模型检测待匹配文本的共现话题,衡量查询和回复之间的共现关系,构造语义融合矩阵,最后用深度神经网络计算匹配分数.

基于卷积神经网络. Hu 等人^[32]提出以语义融合为中心的 ARC-II 模型.该模型分为两层:第一层为卷积层,将查询和回复分别做一维卷积,然后针对两者卷积得到的向量构造对应的特征组合,得到一个二维的特征组合矩阵;第二层是池化层,对特征组合矩阵进行最大池化操作.最后经过多次的卷积和池化操作,得到两个句子语义融合的向量表示,输入到 MLP 中,计算出匹配分数.作者的实验表明,以融合为中心的 ARC-II 模型的匹配效果要优于以表示为中心的 ARC-I 模型.

受卷积神经网络在图像识别领域的启发,Pang




图 17 以融合为中心的单轮检索模型框架示意图

等人^[54]提出 MatchPyramid 模型。其主要思路是将文本匹配任务类比为图像识别任务，首先基于词语之间的相似性构造匹配矩阵，再利用卷积层和池化层逐层捕获融合信息，计算匹配分数。

基于循环神经网络。 Liu 等人^[55]基于递归匹配思路提出深度融合的 LSTM 匹配模型(DF-LSTM)，来模拟两个文本的强相互作用。具体来说，DF-LSTM 由两个相互依赖的 LSTM 模型组成，这两个 LSTM 分别用于捕捉两个词序列内部和外部的语义表示和融合信息。假设，给定两个文本词序列 $x_{1:m}$ 和 $y_{1:n}$ ，DF-LSTM 根据位置 (i, j) 之前的语义融合信息来计算 $x_{1,i}$ 和 $y_{1,j}$ 的语义融合信息 $h_{i,j}$ 。受记忆网络模型的启发，该模型还引入两个外部存储器来保存前面的语义融合信息。作者认为 DF-LSTM 不仅能对相近词语之间语义进行融合匹配，还可以捕捉复杂、长距离的匹配关系。

Wang 等人^[56]基于循环神经网络提出了双边多视角匹配模型(BiMPM)。给定句子 P 和 Q ，BiMPM 模型首先使用 Bi-LSTM 编码器对句子进行编码，再进行 P 到 Q 和 Q 到 P 两个方向的匹配，然后用另一个 Bi-LSTM 将匹配结果聚合成固定长度向量，通过全连接层得到最终的匹配分数。BiMPM 一共提出四种匹配方式，如图 18 所示。

包括(1)完全匹配：每个词语与待匹配句子的最后一个隐藏层输出向量计算匹配度；(2)最大池化匹配：每个词语与待匹配句子的每一个单词进行匹配度计算，再取最大值；(3)注意力匹配：每个词语与待匹配句子的每个单词计算余弦相似度，然后用 Softmax 归一化，作为注意力权重加权求和得到注意力向量表示，与词语计算匹配度；(4)最大注意力匹配：每个单词与待匹配句子中的每个单词计算




图 18 Wang 等人^[56]提出的匹配模型示意图

余弦相似度。然后用 Softmax 归一化，作为注意力权重，取最大值，得到的结果再与词语计算匹配度。作者将这四种匹配方式组合在一起得到最好的实验效果。

基于递归神经网络。 Wan 等人提出的 Match-SRNN^[57]模型基于空间递归神经网络(Spatial RNN)进行文本语义融合计算。该模型将文本融合计算看作一个递归的过程，即每个位置的两个文本的相互作用是它们的前缀之间的语义融合以及当前位置的单词语义融合结果的组合。作者在实验中还尝试结合从前往后和从后往前两个方向的匹配模型(Bi-Match-SRNN)，达到了最优的效果。

3.1.3 表示与融合相结合的框架

一些模型分别实现以表示中心的模型和以融合为中心的模型，再将其组合起来。

基于卷积神经网络。 Mitra 等人^[58]提出包含两个子匹配模型的排序模型。其中，基于单词精确匹配的子模型被称为本地模型，属于以融合为中心的模型；基于词向量的子模型被称为分布式模型，是以表示为中心的模型。两个子模型联合训练，分别通过卷积、池化等深度学习技术计算匹配分数，再将两个子模型的匹配分数相加作为最终匹配分数。

Yu 等人^[59]基于组合表示和融合相结合的模型，实现了检索式问答匹配的跨领域迁移学习，利用已有的标注数据来优化其他领域小规模数据的检索对话效果。模型中的匹配分数计算结合以表示为中心的模型和以融合为中心的模型。如图 19 所示，左

边为以表示为中心的模型,右边为以融合为中心的模型,均基于卷积神经网络技术实现。




图 19 Yu 等人^[59]提出的表示和融合相结合的模型示意图

3.1.4 分析比较

从框架层面看,早期研究中以语义融合为中心的模型能够充分地保留查询与回复之间的语义融合匹配信息,匹配效果要好于以表示为中心的单轮检索模型.就计算效率而言,以表示为中心的模型能够通过预训练将回复语料库提前表示成向量,且语义融合计算较简单,比以融合为中心的模型更适合在线检索回复的任务.近期,随着注意力机制的深入研究,融入注意力机制以表示为中心的模型^[52]达到了最先进的性能.除此之外,还有一些系统同时构建以表示为中心和以融合为中心两个自子系统,捕捉不

同方面的匹配度,来提升系统性能。

从在语义表示和融合的具体应用来看：

(1)深度学习在单轮检索对话中的语义表示应用主要基于卷积神经网络、循环神经网络和注意力机制.其中,卷积神经网络的层级结构具有较好的特征选取能力,可以并行计算,运行速度快,但无法捕捉长距离依赖关系;循环神经网络能够捕捉长距离依赖关系,更适合序列建模,但特征提取能力稍弱.注意力机制则可与卷积神经网络、循环神经网络相结合,对关键信息进行筛选,提升语义的表达性能。

(2)单轮对话检索方法的深度语义融合最早基于深度神经网络,后来提出的模型包括卷积神经网络、循环神经网络和递归神经网络.卷积神经网络直接基于匹配矩阵提取句子级别匹配特征;循环神经网络的匹配模型则有多种匹配方式,其中递归匹配的方式较符合序列匹配思路,被多个研究采用。

3.2 深度学习在多轮检索模型中的应用

与单轮检索对话模型类似,多轮检索模型同样遵循检索-匹配-重排序的操作流程.相关研究大多将深度学习技术应用在匹配过程中,少数用在重排序步骤.与单轮模型最大的区别在于,多轮对话系统需要整合当前的查询和历史对话信息作为输入,目标是选择既与查询相关,又符合历史对话语境的语句作为回复。

下面将对话的多轮检索模型分为以表示为中心、以融合为中心和面向重排序三类框架展开介绍.相关文献分类整理如表 3.

表 3 深度学习在多轮检索模型的应用

分类	文献	深度学习模型
以表示为中心的框架	Lowe 等人 ^[24] , Inaba 等人 ^[61]	循环神经网络
	Zhou 等人 ^[62] , Yan 等人 ^[63]	卷积神经网络、循环神经网络
	Wu 等人 ^[64]	卷积神经网络、循环神经网络
以融合为中心的框架	Zhang 等人 ^[65]	循环神经网络、注意力机制
	Zhou 等人 ^[66]	注意力机制
基于重排序的框架	Yan 等人 ^[67]	卷积神经网络、循环神经网络

3.2.1 以表示为中心的框架

以表示为中心的多轮检索模型着力于用深度学习模型将对话上下文信息表示成语义向量,再计算其与回复的匹配分数,框架示意图如图 20.

其中, u_1, u_2, u_3 表示对话上下文话语, r 表示候选回复。

基于循环神经网络. Lowe 等人^[24]在发布 Ubuntu 多轮对话数据集的同时提出基于 RNN 的基准模型(Baseline Model).该模型不区分历史对话信息和查询,将其拼接在一起作为输入,首先基于 TF-IDF 模型找出相似度最高的候选回复,再用




图 20 以表示为中心的多轮检索模型示意图

RNN/LSTM 模型将句子转为向量表示计算匹配分数. Inaba 等人^[61]提出了基于 RNN 编码器框架的

神经对话排序模型. 其基本思想是, 用构建两层 RNN, 一层用于提取文本向量表示, 在另一层用于候选回复排序.

基于卷积神经网络和循环神经网络. Zhou 等人^[62]提出了多视角的多轮对话检索模型. 该模型将对对话上下文信息作为输入, 并从词序列和话语序列两个视角来计算匹配分数, 最终结合两个分数来选择回复. 其中, 基于词序列的视角将文本中所有词按顺序输入到一个 GRU 中, 将其隐藏向量作为文本的语义表示; 话语序列的视角则基于卷积神经网络, 先通过卷积和池化得到每个话语的表示, 再输入到另一个 GRU 中输入文本的表示.

Yan 等人^[63]提出用历史对话信息来重构查询的思路实现多轮检索对话. 其主要思路是: 基于历史对话重构的查询可以捕捉历史对话中不同方面的特征信息, 在回复选择时综合考虑原始查询和重构的查询, 可以增强回复与历史对话语境的相关性. 假设历史对话信息 c 中有 N 个句子, 作者用 5 种方法重构新查询集合: (1) 无历史对话: 不加入 c 中的句子; (2) 全部历史对话: 加入 c 中全部的句子; (3) 加一条: 每次加一个 c 中的句子; (4) 减一条: 每次加 $N-1$ 个 c 中的句子; (5) 上述四种方法结合. 具体来说, 该模型首先将句子的词序列输入到 Bi-LSTM 中, 再使用卷积神经网络具体得到句子的向量表示. 并根据重构方法得到重构查询集合, 将集合中的重构查询与候选回复、先前帖子、原始查询的向量表示分别拼接, 经过 MLP 后整合成最终的匹配分数.

3.2.2 以融合为中心的框架

以融合为中心的多轮检索模型着力于计算回复

与对话上下文中话语的语义匹配特征. 相比以表示为中心的模型, 该框架计算回复与每个话语的融合信息, 在更细的语义融合粒度上计算对话上下文信息与回复的匹配分数. 如图 21 所示.




图 21 以融合为中心的多轮检索模型示意图

基于卷积神经网络和循环神经网络. Wu 等人^[64]提出序列匹配网络 (Sequence Matching Network, SMN) 框架实现了以语义融合为中心的多轮检索对话系统, 如图 22 所示. 序列匹配网络的主要思想是: 首先对候选回复与上下文中的每个话语分别计算语义融合得到匹配矩阵, 再用卷积和池化操作提取每个话语-回复对的重要匹配信息; 然后按话语在上下文中的顺序依次输入到一个 GRU 中累计这些匹配信息, 从而得到整个上下文和候选回复之间的匹配关系; 最后, 基于 RNN 的隐藏层向量计算最终的匹配分数.




图 22 Wu 等人^[64]提出的序列匹配模型示意图

基于循环神经网络和注意力机制. Zhang 等人^[65]提出的多轮检索对话模型中,语义表示和语义融合过程均用深度学习模型.在语义表示过程中,模型首先将查询分别与对话历史话语和回复拼接,并先后采用自注意力机制和 GRU 得到每个话语的语义表示;语义融合过程则是基于词粒度和句粒度两个匹配矩阵,用卷积、最大池化和扁平化方法计算出每个话语与查询的匹配特征向量.最后,将话语和查询的匹配特征向量按顺序输入到 GRU 中计算出最终的候选回复匹配分数.

基于自注意力机制.受到机器翻译系统 Trans-former^[40]的启发,Zhou 等人^[66]打破循环神经网络和卷积神经网络结构,仅基于注意力机制实现了多轮检索对话的匹配模型.该模型的语义表示基于多层的自注意力机制,即将句子的词向量矩阵经过多次自注意力计算得到一组句子表示矩阵.其语义融合的过程构建两种匹配矩阵来提取上下文和查询的匹配特征:(1)自注意力匹配(self-attention-match),直接将自注意力得到的话语和回复表示矩阵点乘得到匹配矩阵;(2)交叉注意力匹配(cross-attention-match),计算话语投影到回复的表示矩阵和回复投影到话语的表示矩阵.这两个表示矩阵能够捕捉话语和回复语义结构,使得有依赖关系的段在表示中相互接近,从而得到基于依赖关系的匹配矩阵.最后将匹配矩阵组合起来,经过最大池化和感知机得到最终的匹配分数.

3.2.3 基于重排序的框架

深度重排序模型.Yan 等人^[67]提出一种排序-重排序模型,先根据查询检索出候选回复,再根据历史对话信息,对候选回复进行重新排序,使得最终给出的回复不仅和查询相关,也和历史对话语境相关.该文中句子建模可采用循环神经网络、卷积神经网络等深度学习模型.这种方法中,粗粒度地候选回复筛选仅与查询有关,历史对话信息对回复的影响有限,相关研究也很少.

3.2.4 分析比较

从框架层面看,以表示为中心的多轮检索对话

模型,在语义表示计算过程与回复独立,会丢失一些特征.以融合为中心的多轮检索对话模型能够提取和保留上下文中对匹配回复有用的信息,较前者匹配效果更好,但是算法更复杂、计算量更大.

从深度学习技术的具体应用来看:

(1)多轮检索对话中的深度学习语义表示模型用到循环神经网络、卷积神经网络、注意力机制.与单轮对话不同,多轮检索对话需要对历史对话话语和查询的组合方式建模,其组合方式可以分为:①直接拼接为词序列:由于不同历史对话与查询的相关性不同,直接拼接会引入噪音;②合并为话语序列:将历史对话和查询视作话语序列,这种方法也降低了查询对回复的影响;③根据历史对话对查询进行扩展:这种方法复杂度较高,很难穷举所有的对话历史选择可能性,而仅扩展有限的查询组合提升性能有限;④基于注意力机制将查询与对话历史话语逐一组合:该方法能够弥补前面方法的不足,根据对话历史话语与查询的相关性,计算对话上下文的语义表示,减少噪音影响.

(2)随着研究的深入,多轮检索对话中的语义融合计算越来越复杂,使用的深度语义融合模型包括循环神经网络、卷积神经网络和注意力机制.其中,循环神经网络可根据上下文话语顺序来计算匹配度,卷积神经网络则直接根据匹配矩阵提取特征.近期研究表明,应用自注意力机制的模型达到了当前最优的匹配性能^[64].

3.3 深度学习在单轮生成模型中的应用

受到基于短语的统计机器翻译技术^[68]启发,2011 年 Ritter 等人^[69]提出一个生成回复的概率模型.它将生成回复视为翻译任务,即将输入查询翻译成回复.但是由于对话回复多样性的特点,该任务比翻译任务要更困难,所以直到基于深度神经网络模型的成功,才真正激发学者们对生成式对话系统的研究热情.根据系统实现的基础框架,本文将单轮生成模型序列到序列模型框架、神经语言模型框架和强化学习框架三类,相关文献整理如表 4.

表 4 深度学习在单轮生成模型的应用

分类	文献	深度学习模型
序列到序列模型框架	Shang 等人 ^[12] ,Shao 等人 ^[70] ,Wang 等人 ^[71] ,Wu 等人 ^[72] ,Shang 等人 ^[73]	序列到序列模型、循环神经网络、注意力机制
神经语言模型框架	Mei 等人 ^[74]	神经语言模型、循环神经网络、注意力机制
强化学习框架	Li 等人 ^[75] ,	强化学习、序列到序列模型
	Li 等人 ^[76] ,Xu 等人 ^[77]	生成对抗网络、序列到序列模型

3.3.1 序列到序列模型框架

绝大多数的单轮对话生成基于序列到序列模型框架建立端到端的对话模型,根据给定的查询语句生成回复。

引入注意力机制. Shang 等人^[12]最早基于新浪微博^①构建语料库,并采用序列到序列模型框架实现单轮对话生成系统.模型首先用编码器 RNN 对查询进行编码得到其语义向量表示,再用解码器 RNN 对该语义向量解码得到回复序列.模型解码器 RNN 在每个时刻输入的语义向量包含两个来源:一是全局编码器(global encoder)计算的全局语义向量,二是局部编码器(local encoder)基于注意力机制加权计算的局部语义向量,如图 23 所示。




图 23 Shang 等人^[12]提出的单轮对话生成模型示意图

作者认为将全局编码器和局部编码器同时训练时,全局编码器训练不充分,所以提出先分别训练两个子模型,再将两者合并利用微调的方法优化.训练阶段以给定查询最大化训练集中真实回复概率为目标,预测阶段则采取集束搜索(Beam Search)的方法来生成回复。

注意力机制纳入部分目标序列. Shao 等人^[70]注意到基本的序列到序列模型中,解码器没有将生成词纳入到注意力的计算中,导致很难生成信息量大的长回复.他们提出将已生成序列作为一部分加入到注意力机制的关注中.该模型具有固定长度的解码器,且编码器最后一个节点的隐藏向量始终直接连接解码器的初始向量,如图 24 所示。




图 24 Shao 等人^[70]提出的对话生成示意图

具体来说,在训练时,作者将输出序列分割成固定长度且不重叠的连续片段构造新的训练数据.假设回复 y 被分割成 y_1 和 y_2 ,则查询-回复对 $x \rightarrow y$ 分割后将形成两对训练数据 $x \rightarrow y_2$ 和 $x, y_1 \rightarrow y_2$.在预测时,片段内采用集束搜索,片段级别使用归一化分数进行重排序。

动态的解码器词典. 在序列到序列模型框架下,解码所有回复的词语都从相同的词典生成.为了保证回复多样性,词典规模大,解码成本高,也容易受到噪声影响. Wu 等人^[72]对解码阶段的词语映射进行改进,提出一种基于动态解码词典的序列到序列模型(DVS2S),使得每步解码根据当前对话实际有不同的词典,以去除不相关词汇的干扰,缩小映射范围,加快解码速度.在训练时,该模型同时学习动态词典构建和回复生成.在预测中,模型使用预测模型动态地为输入分配相应的小词汇表,并且仅使用小词汇表进行解码.作者的实验结果表明在不影响解码质量的情况下,在线解码生成的速度提高 40%。

增加校准机制. Shang 等人^[73]针对对话语料库中包含噪音的情况提出校准机制.其主要思想是:用基于深度神经网络的对话质量评价指标对训练语料库中的查询-回复对打分,根据其分值高低决定训练时对模型的影响程度.框架示意图如图 25 所示,训练时,系统根据训练数据的打分来对损失值加权反馈给模型。




图 25 Shang 等人^[73]提出的单轮对话生成模型示意图

3.3.2 神经语言模型框架

神经语言模型对给定前面的词语能预测下一个词语,所以可以直接基于该框架建立生成式模型。

基于循环神经网络语言模型+注意力机制. Mei 等人^[74]基于 RNN 的神经语言模型同时加入动态注意力机制实现单轮对话生成系统.其主要思路是建立一个基于 RNN 的语言模型,将词序列按顺

① <http://weibo.com>

序输入模型计算隐藏向量,并在每个解码时刻对所有前面的隐藏向量应用注意力机制,计算出赋权的上下文语义向量,然后根据该向量和 RNN 模型的隐藏向量计算输出.与序列到序列框架的注意力模型相比,这种方法的特点是为每个生成步骤提供不同的输入做参考.作者还预训练话题模型,在文档级别选择最佳话题匹配作为生成回复,保证话题延续.

3.3.3 基于强化学习框架

在强化学习框架下,系统可以与外部环境交互,通过做出决策、采取动作、获得奖赏来指导和改进模型.

基于强化学习. Li 等人^[75]在生成式对话系统中引入强化学习模型来整合奖励策略并建立长期影响机制.该模型使用序列到序列模型学习对话中的语义关系,使用强化学习模型优化长期对话机制.作者提出从三个方面来评价对话,(1)连贯性.连续轮转之间的语义相似性;(2)信息流.同一个人的话,应该在语义上移动避免语义重复;(3)轻松回答.话语能很容易给出好的回复.模型采用策略梯度方法来奖励表现良好的回复.该模型基于预定义的评价指标作反馈,这种人为定义的评价标准比较死板.

基于生成对抗网络. Li 等人^[76]采用对抗学习^[43]的思想,同时训练的回复生成器和回复判别器两个模型.其中,生成器是基于序列到序列模型的生成式对话模型;判别器是一个二分类模型,将生成的回复分为人回复和机器回复两类,用于评估回复的

质量.该框架的关键思想是鼓励生成器生成与人类回复无法区分的话语. Xu 等人^[77]也将生成对抗网络用到对话生成任务,它提出用近似嵌入层来代替解码器中的采样解码结果,整个模型连续可导,使得判别器可以将误差反向传播到生成器.

3.3.4 分析比较

单轮生成对话任务中使用的深度学习技术包括神经语言模型、循环神经网络、注意力机制、生成对抗网络.虽然 Mei 等人^[74]提出基于神经语言模型的对话生成效果要优于序列到序列模型的对话生成效果,但是绝大多数的系统还是改进序列到序列框架.

针对序列到序列框架的改进可以分为两大类:一类是对模型效果的改进,相关工作包括改进编码器、引入注意力机制、改进解码器、数据校准等;一类是对模型效率的改进,例如通过使用动态词典来提升系统的解码速度.

基于强化学习框架的单轮对话生成系统在序列到序列模型基础上引入反馈机制,能够进一步改进模型效果.

3.4 深度学习在多轮生成模型中的应用

真实对话通常有多轮,对话回复需要考虑历史对话信息,近期的生成式对话研究也重点关注多轮对话任务.根据系统实现框架,本文将多轮生成对话系统分为基于序列到序列模型框架、基于神经语言模型框架和基于层次序列到序列模型框架,相关文献如表 5.

表 5 深度学习在多轮生成模型的应用

分类	文献	深度学习模型
序列到序列模型框架	Vinyals 等人 ^[78] , Yao 等人 ^[79]	循环神经网络
	Wang 等人 ^[71] , Yan 等人 ^[80]	循环神经网络、注意力机制
神经语言模型框架	Sordoni 等人 ^[21]	神经语言模型
层次序列到序列模型框架	Serban 等人 ^[81] , Serban 等人 ^[82] , Serban 等人 ^[83] , Tian 等人 ^[84]	循环神经网络、注意力机制
	Chen 等人 ^[85]	循环神经网络、记忆网络

3.4.1 序列到序列模型框架

基于基本的序列到序列模型. Vinyals 等人^[78]最早基于序列到序列模型的构建多轮对话生成系统.他们的模型基于循环神经网络,将对话上下文统一作为输入,一次读取一个词语.在训练期间用真实回复中的上一个词作为预测时的输入;在预测时用上一个词的预测输出作为当前时刻输入.该模型较简单,但是却为许多问题生成了恰当的答案,开启了利用深度学习技术构建生成式对话系统的研究.

融入意图网络的序列到序列模型. Yao 等人^[79]提出的多轮对话生成模型包括三个模块:编码器、意

图网络和解码器.每个模块都使用循环神经网络.其中编码器和解码器的构建与 Vinyals 等人^[78]提出的模型一样,意图网络用于记忆对话意图历史信息.

多信道编码器. Wang 等人^[71]对对话语料进行分析,发现上下文中只有不超过 45.2%的短语直接有助于回复生成,于是提出在序列到序列模型的编码器上增加深度信道(Deep Channel)和宽度信道(Wide Channel)来进一步提取对生成回复有用的信息.其中,宽度信道采用带注意力机制的循环神经网络来预测没有出现在对话中,但与输入话语相关的关键字;深度信道则通过训练多层感知器模型来选

择输入话语中已有的词作为关键字。最后,将深度信道和宽度信道预测的关键词和输入话语一起传给解码器,再用注意力机制的解码器来生成回复。

利用对偶序列到序列模型进行对话建议。 Yan 等人^[80]对给定上下文信息输出回复的基本对话范式进行扩展,提出了上下文-回复-对话建议的范式。其主要思想是:在上下文编码器和生成回复解码器外,加入一个基于深层双融合单元的序列到序列模型作为对话建议的解码器,对当前回复的下一个回复进行预测。具体来说,作者提出的深层双融合单元包括:顺序 GRU 单元、对齐 GRU 单元以及融合单元。该单元能够深度融合来自双序列的信息,并解码生成对话建议。

3.4.2 神经语言模型框架

基于神经语言模型。 Sordoni 等人^[21]在 2015 年提出了基于神经语言模型的多轮对话生成模型。作者共提出三种组合历史对话话语和当前查询的方法来训练神经语言模型。在预测阶段,模型计算概率最大的语句作为回复。三种方法如图 26 所示。




图 26 Sordoni 等人^[21]提出的多轮对话生成模型示意图

(1) RLMT. 将历史对话话语-查询-回复串联起来,训练神经语言模型;(2) DCGM-I. 基于神经网络模型将历史对话话语-查询合并表示成固定长度,训练神经语言模型;(3) DCGM-II. 将历史对话话语和查询分别经过线性映射再拼接成固定长度向量,作为神经语言模型的输入。其中,RLMT 和 DCGM-I 模型不区分历史对话话语和查询,会减弱查询和回复之间的依赖关系,DCGM-II 也仅仅将历史对话话语和查询做简单区分。

3.4.3 层次序列到序列模型框架

Li 等人^[86]提出的层次编码器-解码器模型对文本序列的层次结构建模,可直接对多轮对话系统建模。不少研究工作基于该模型开展。

基于层次序列到序列模型。 Serban 等人^[81]基于层次序列到序列模型构建了对对话上下文话语序列

建模的对话模型(HRED)。该模型包含(1)话语级模型(Encoder RNN)。基于循环神经网络将单个话语中包含的词序列向量表示转换成话语的向量表示,主要用来捕捉每个话语的表示语义;(2)话语间模型(context RNN)。基于循环神经网络将多个话语的向量表示转换成对话上下文的向量表示,用来将历史对话和查询的信息集成在一起。最后,将根据话语序列顺序计算的上下文表示输入到解码器(decoder RNN)中解码。但是,HRED 模型相对于标准的序列到序列模型性能提高并不明显。

Serban 等人^[82]认为 HRED^[81]模型回复生成词语时的采样是浅层的,提出了基于潜在变量的层次编码器解码器模型(VHRED)。该模型在 Context RNN 中引入一个随机变量,解码过程先采样出潜在变量,再生成序列。其中的潜在变量可以是情感或话题,能对回复进行初步分类。由于 VHRED 可以通过潜在变量分布对对话中的不确定性建模,故能生成信息更丰富的回复。

Serban 等人^[83]继续对 VHRED 做改进提出了 MrRNN 模型。MrRNN 由两个并行的 HRED 模型构成:一个对粗粒度序列建模(作者定义为文本中的名词序列或谓词-参数对);另一个对完整词序列建模。其中,完整词序列 HRED 中的解码基于粗粒度序列 HRED 模型的解码结果。根据约束条件,粗粒度序列包含更多的语义信息,能够缓解自然语言的稀疏性问题,所以 MrRNN 表现出更好的性能。

Tian 等人^[84]通过计算历史对话话语与查询相似度作为权重来衡量话语对生成回复的重要程度,再基于权重来整合对话上下文表示,最后基于层次序列到序列模型实现多轮对话生成。具体来说,该模型先将历史对话话语和当前查询表示成向量形式,用余弦相似度计算相似度作为权值,最后用加权求和/加权拼接的方式整合历史对话信息和查询。

基于层次序列到序列模型+记忆网络。 Chen 等人^[85]提出在层次序列到序列模型中增加变分记忆网络的模型(HVMN),HVMN 将变分自编码器^[87]和记忆网络^[42]结合起来跟踪对话的长期记忆,实现对历史对话高级抽象信息的存取。具体来说,先根据编码器隐藏向量 h 计算出潜在变量 z ,再将 z 和记忆网络 M 结合计算出变分记忆网络模块的输出 b ,如下图所示。最后根据 b 、上下文向量表示、上一时刻解码输出和上一时刻解码隐藏向量一起预测当前时刻输出。如图 27 所示。




图 27 Chen 等人^[85]提出的记忆网络模块示意图

3.4.4 分析比较

深度学习在轮对话生成中的应用主要包括神经语言模型、序列到序列模型、注意力机制和层次序列到序列模型。早期的模型大多基于不分层的结构（包括神经语言模型和序列到序列模型）。但是，在不分层的框架中，无论是直接拼接历史话语和查询，还是按顺序接收话语作为输入，都会减弱查询和回复之间的依赖关系，引入噪音。近期的多轮对话生成模型大多基于层次序列到序列模型框架实现，并通过改进该框架来优化对话上下文的向量表示。将基于层次框架的模型和基于不分层框架的模型相比，改进的层次框架模型对话语层级关系直接建模，效果更好，能生成更多样、更有意义的回复。

3.5 检索与生成相结合的方法

3.5.1 单方法模型分析

基于检索方法的对话系统中回复是人的真实话语，所以语句质量较高，语法错误少，是目前工业应用的主流技术。但是检索的方法的前提是预设对话语料库中存在能作为回复的话语，也就是说，大规模语料库是检索式系统成功的关键^[9]。有限的存储规模成为检索数据库无法突破的瓶颈。也就是说，即使检索存储库非常大，如果对给定的查询话语没有适当的回复时，系统也不能创建新回复。

生成式对话系统逐渐成为研究者关注的热点。然而虽然生成式对话系统取得很大进展，能够“创造性”地生成回复。且使用和维护成本低、可覆盖任意话题的查询，但是这些系统生成回复质量不可控。缺点是生成回复质量不可控，甚至可能有语句不通顺、句法错误等问题。具体来说：

(1) 倾向于生成缺乏语义信息的“万能回复”。由于生成式对话系统生成回复的过程不可控，系统直接从训练数据中学习模式生成回复，而“我不知道”、“好的”等缺乏语义信息的“万能回复”在训练数据中出现的频次较高，最大似然估计的方法使得模

型倾向于生成这样的回复^[88]。

(2) 生成句子的质量不能保证。基于生成的系统较为灵活，可以在相对较小的词汇表和较小的训练数据集的情况下创建无限回复。然而，生成的句子并不总能保证是自然的、流畅的和合理的^[63]。

(3) 生成式方法的训练和预测的解码过程不一致影响生成质量。生成式对话系统的回复话语生成的过程对应着序列到序列模型中的解码过程，而实际训练和预测过程中，解码方法不完全相同。训练时，输入对应的输出已知，所以每一个词语生成时，使用真实上一时刻输出词作为当前时刻的输入；而在预测阶段输出未知，通常采用集束搜索方法来解码^[12]。另外，生成式方法在训练模型时使用词语级别损失函数，测试时通常采用序列级评估指标，二者不完全统一。

3.5.2 检索与生成相结合的方法

一些研究尝试将检索式方法和生成式方法集成起来建立开放领域对话系统，目标是结合检索模型和生成模型的优点。Song 等人^[25]使用检索模型检索到的候选结果和查询同时作为序列到序列模型中编码器的输入生成结果，然后再将该生成结果加入原检索候选集中，进行重新排序，使得对于一个输入，系统能够从不同的渠道输出优化的结果，从而提升回复质量。Cho 等人^[89]同样将两个模型进行融合，先通过传统的检索模型从问答知识库中找出候选答案集合，然后训练带注意力的序列到序列的生成模型对候选答案进行重排序。在选择回复时，如果第一候选回复的得分超过某个阈值，就直接输出该回复，否则利用生成模型生成结果作为回复。

4 基于深度学习的开放领域对话系统的关键问题

基于深度学习的开放领域对话系统以数据驱动为基础建立最大化语料库概率的对话模型。但由于对话语料库没有根据场景、目的、个性化等特征信息做区分，使得建立的对话模型存在一些关键问题待解决。

4.1 回复多样性

开放领域对话系统最典型的特点是，对于用户给定的查询，存在多个合理的回复，这种现象被称为“一对多(One-to-many)”的多样性。检索式对话系统的回复内容控制可以通过选择不同的候选回复实

现. 而对于生成式对话系统, 模型的特点决定其倾向将出现概率更大的通用话语作为回复, 诸如“我不知道”、“我也是”等通用回复. Li 等人^[88]对对话语料分布进行分析, 他们的数据中有 0.45% 的回复是“我不知道”, 而相对信息量更大的其他回复则出现概率较小. 虽然通用回复也是合理回复, 但是没有太大的意义. 所以提高回复多样性是提升生成式对话系统效果一直在努力的方向.

最大互信息目标函数. 在生成式对话系统中, 降低通用回复概率最直接的方法是找到一个更好的目标函数. Li 等人^[88]提出一种基于最大互信息的优化目标, 将标准目标函数 $\log p(\mathbf{r}|\mathbf{q})$ 修改为 $\log p(\mathbf{r}|\mathbf{q}) - \log p(\mathbf{r})$. 这种方法使得被选中的回复不仅取决于给定用户查询生成回复的概率, 也取决于给定回复生成用户查询的概率, 以限制通用回复, 从而提升回复信息多样性.

改进排序规则. 改进候选回复的排序规则也可以实现对话内容控制. 检索式对话系统可以直接改进候选回复的排序. 而生成式对话系统改变候选排序在解码阶段完成. 序列到序列解码用到的集束搜索算法会产生冗余的候选回复, 可以从中挑选出具有多样性特征的回复.

一些研究通过改进集束搜索来提高模型性能. Vijayakumar 等人^[90]认为对话生成不是唯一正确答案的任务, 提出用一个度量候选序列之间多样性差异的方法扩大集束搜索的搜索目标, 来探索不同路径解码结果来避免局部最小值. Shao 等人^[70]结合优化过的解码模型引入随机集束搜索. Li 等人^[91]提出在解码过程中, 通过计算参考分数, 使得来自于同一个祖先序列的子序列尽量不被同时选中.

还有一些研究直接对候选进行重排序. Yao 等人^[92]引入逆文档频率 (IDF) 对候选进行重排序. Song 等人^[93]提出使用最大边际关联法则 (Maximal Marginal Relevance, MMR) 来对候选进行重排序.

引入潜在变量. 据对话对象、对话场景等特点, 人们对于同一信息的回复可能不同, 但是生成式对话模型中的回复都是从一个确定性的编码器-解码器模型中采样. 一些工作通过引入潜在变量, 先对潜在变量的分布进行采样, 再根据分布进行解码, 来生成以潜在变量为根据的回复.

Cao 等人^[94]提出一种基于潜在变量的单轮对话生成模型. 该模型在解码器中包含通过变分自编码器的随机变量 z , 模型训练的目标函数变为最大

化条件概率 $p(\mathbf{r}|\mathbf{q}, z)$. Serban 等人^[82]将潜在变量的方法引入到层次结构的对话模型中. 其潜在变量还可以有更具体的定义, 例如话题或者情感. Shen 等人^[95]对潜在变量的属性进行明确的条件限制, 让这些属性更具有可解释性. 属性可以手动设置也可以自我学习. Zhou 等人^[96]提出编码器-转向器-解码器模型来模拟对话中的语义的潜在响应机制, 使得不同机制生成不同的回复. Zhao 等人^[97]基于条件变分自编码器模型, 以多种语义意图为条件构建对话模型.

多头注意力机制. Tao 等人^[98]应用多头注意力机制来捕获查询话语中不同方面的语义, 并通过正则化目标函数使得回复包含更多样化且仍与给定查询更相关. 该模型的关键在于构建多个可学习的投影矩阵, 再用点乘的计算方法将编码器 RNN 的隐藏状态投影到多个不同的语义空间, 最后将多头注意力的语义向量加权求和输入到解码器中, 使得生成的回复更多样.

基于行列式点过程. Song 等人^[99]提出两种将行列式点过程与生成模型结合的方法, 来提升生成对话中查询级别和系统级别两个粒度的多样性.

4.2 话题控制

话题模型 (Topic Model) 是在大量文本中发现抽象话题/主题的一种统计模型. 直观来说, 文本包含一定的话题, 与这些话题有关的词语会更频繁的出现. 话题模型已经被应用到文本分类等自然语言处理领域, 取得不错的效果.

检索式对话中引入话题线索. Wu 等人^[100]提出用卷积神经网络模型结合话题信息对查询和回复进行语义表示. 具体来说, 该模型先用卷积神经网络将查询和回复表示成句向量, 并根据 Twitter 基于 LDA 训练的话题模型计算出其话题加权的向量表示, 再将查询分别与回复和回复话题的向量表示进行语义融合, 回复也与查询及查询话题的向量表示进行语义融合, 实现基于话题的回复选择.

生成式对话中引入话题线索. Xing 等人^[101]注意到人们在对话的时候常常把对话跟相关的概念联系起来, 并根据概念形成对话的回复. 他们先基于 LDA 模型学习对话数据的话题, 然后将话题信息和输入表示联合起来作为注意力机制的组件来生成与话题相关的回复. 后来, Xing 等人^[102]基于注意力机制对之前工作^[101]中的解码器做改进. Choudhary 等人^[103]对话题问题做更加详细的解析, 他们将查询

中的每一个词语进行分类,先计算查询语句的领域,再依次生成回复的内容。

4.3 引入外部知识

人类交流和对话系统的一个重要区别在于是否与现实相结合.将外部知识库和对话训练语料相结合是弥补系统和人类之间背景知识差距的一个方法。

检索式对话中引入外部知识. 匹配模型是检索式对话系统成功的关键,将外部知识引入到匹配模型可以增强匹配特征,优化匹配效果. Lowe 等人^[104]提出先用 TFIDF 选择与对话上下文相关的非结构化文本的外部知识,再通过知识编码器 RNN 进行知识表示,最后计算候选回复匹配分数时同时考虑与上下文和外部知识. Young 等人^[105]提出将常识知识图谱存储在外部记忆模块的方法,采用 Tri-LSTM 模型分别编码查询、回复和常识,将相关常识整合到检索式对话的匹配模型中. Yang 等人^[106]提出将外部问答知识融合到检索方法的深度匹配模型中. 该方法首先从外部问答知识库中检索与候选回复相关的问答对作为外部知识来源,然后从中提取关键信息扩展候选回复,并将扩展后的匹配特征加入到匹配分数计算,改善上下文和候选回复的匹配效果. Wu 等人^[107]针对语义和句法结构复杂的长文本的语义匹配问题,提出用先验知识识别长文本中 useful 信息并过滤噪音的模型,来增强文本表示,提升匹配性能。

生成式对话中引入外部知识. 生成式对话系统中通常通过增加与对话上下文相关的知识型语义表示,为解码器提供更丰富的信息. Zhu 等人^[108]提出的 GenDS 模型,用对话上下文中的实体相关的事实知识来增强上下文的语义表示. Vougiouklis 等人^[109]预先用卷积神经网络对带分类信息的维基百科语料库训练句子表示模型. 在对话系统训练和预测时,用预训练的句子表示模型计算输入的语义表示,再与基础序列到序列模型中的解码器 RNN 隐藏向量拼接来解码生成回复. Ghazvininejad 等人^[110]用记忆网络建立了一个基于知识库回答的开放领域对话生成系统中. 其核心思想是先在对话上下文中找到知识库中的知识,并将知识转换为语义向量表示与对话上下文向量表示整合输入到解码器中生成回复. 最近, Zhou 等人^[111]用注意力机制将对话生成模型与大规模知识图谱技术相结合. 他们的系统包含三个模块:编码器-解码器模块、知识解释

模块和知识生成模块. 知识解释模块采用基于静态的注意力机制,将词向量和检索到的知识图谱图形向量连接. 知识生成模块采用动态的注意力机制,根据关注权重来读取图中影响选择生成的词语。

4.4 融入情感

“悲你所悲,喜你所喜”,真正的情感抚慰和陪伴需要融入情感的对话,可以称之为情感智力 (Emotion Intelligence). 情感智力是成功的、智能的对话系统中不可或缺的重要组成部分. 与检索式方法相比,生成式方法更灵活、更方便融入情感。

基于记忆网络. Zhou 等人^[112]首先将情感因素引入到生成式对话系统,提出基于记忆网络的情感对话系统 (Emotional Chatting Machine, ECM). 他们在传统的序列到序列模型的基础上,使用了静态的情感向量表示、动态的情感状态记忆网络和情感词外部记忆的机制,使得 ECM 可以根据指定的情感分类输出对应情感的回复。

基于带情感的词向量. Asghar 等人^[113]针对对话中的情感问题从以下三方面对序列到序列做改进: (1) 引入带情感信息的词向量. 这个词向量共有三维,每一维度代表情感的一个因素; (2) 提出三个与情感因素相关的损失函数:最小化情感失调、最大化情感失调、最大化情感内容; (3) 在解码时考虑情感,让解码出来的候选回复的情感尽可能不一样,增加多样性。

基于条件变分自编码器. Zhou 等人^[114]利用社交网络 Twitter 数据中的表情符号建立了一个大规模、有情感标签的对话数据集,训练表情符号的向量词典,并基于条件变分自编码器构建以表情符号为条件生成回复的开放领域对话模型。

4.5 个性化回复

人在说话的时候有个性的偏好,且对话语的理解能力也因为年龄、认知及其他因素的影响而各不相同. 有效的对话系统应该主动适应当前用户,给出适合他们的回复. 当前,大多数训练数据集包含不同人的对话,但是基本的对话模型对于不同说话人不作区分,所以通用模型不能解决个性化回复问题. 一些研究基于生成式方法研究个性化的对话模型。

融入个性化向量表示. Zhang 等人^[115]首先使用通用数据集训练得到对话生成模型,再利用包含用户信息的数据集调整模型,使得生成的回复具有个性化的背景信息. 模型中的用户信息由向量表示. Li

等人^[116]探索了两种个性化对话模型:(1)一元说话者模型. 将说话者信息表示向量整合输入到模型中;(2)二元说话者模型. 将说话者和说话对象信息表示合并,看作交流模型的向量表示. 与之前的工作不同,Engonopoulos 等人^[117]认为人工定义的用户分组无法反映数据的真实特性也不能高效的扩展新用户,因此引入在训练对话模型的过程中同时训练出的用户组特征信息的模型,使得系统能够根据不同用户自动产生相应的回复.

基于双向解码器模型. Qian 等人^[118]在生成回复时结合用户的个人资料信息. 其主要思想是,存储与用户相关的属性键值对,给定查询先用注意力机制探测是否包含属性键,如果包含则以其对应属性值为起点分别向前向后解码,生成包含确定属性值的回复.

4.6 主动对话

标准的对话系统假定只有人类会主动的提出话题参与聊天,计算机只需要根据人类话语给出回复,这样的过程是“被动的”^[119]. 智能的对话系统应该具备根据对话场景调整对话内容或者主动引入新信息的能力,尤其是当对话陷入僵局时,系统应主动提出新话题打破尴尬.

检索式对话系统中的主动建议. Li 等人^[119]提出的 StalemateBreaker 主动对话系统,能够在恰当的时候主动引导新内容新话题. 具体说来,系统从“何时引导”、“引导什么”及“如何引导”三方面进行探索,首先是发现用户认为当前话题无趣的时刻,接着通过挖掘知识图谱寻找可以引导的新话题,并从语料库中检索出候选回复,最后用一个排序算法算出最佳回复. Yan 等人^[120]受到传统信息检索系统中查询建议的启发,提出对话建议的思路. 具体来说,该方法将回复排序和建议排序联合学习,使得检索出的回复不但能回应当前查询,还能够积极地引导下一轮对话.

生成式对话系统中的内容引入. 基本的生成式对话系统倾向于生成通用回复. 一些研究者提出用主动内容引入的方式来生成对话. 其中有两个关键技术点:一是通过门控机制来修改神经网络中的神经单元^[121-122]实现在生成过程中加入额外的线索词;二是回复中线索词的体现方式包括显式和隐式两种:显式方式是指在回复话语中明确包含线索词;隐式方式是指将线索词的语义隐含地包含在回复话语中. Mou 等人^[123]提出的 Seq2BF 模型先预测关键

词并从关键词开始生成回复,由于模型要求关键词必须出现在回复语句中,故称为显示内容引入. Yao 等人^[124]认为通常回复语句中只要表达出线索词的语义信息即可,提出隐式的内容引入方法,利用层次型融合单元来灵活地加入额外地线索词信息. 两者相比,显式的方式比较死板,隐式的方式更灵活但存在不可控的风险.

4.7 交互对话

真实的对话是交互式的,让对话系统具备更强的交互能力也是系统成功的关键. 在线交互能力有两个可努力的方向:一是收集用户反馈,改进对话回复模型;另一个是学会提问增强系统交互性.

基于在线反馈. Asghar 等人^[125]提出在线反馈对话模型分两阶段训练:一是离线阶段的监督学习;二是在线交互时的主动学习. 在线主动学习的思路是,先跟据离线模型生成 k 个回复,用户从中选出一个或提交第 $k+1$ 个作为最佳回复,系统根据用户选择来优化回复生成模型. Li 等人^[126]尝试用在线方式收集并量化人类在对话中的真实反馈,在交互中提高系统生成回复的能力.

基于在线提问. Li 等人^[127]针对对话交互过程中系统容易出现的三类错误分别给出在线提问的解决方案:(1)当系统接收的查询存在拼写错误等情况时,主动提出让用户确认该错误的问题;(2)当系统无法进行知识推理时,主动请求用户给出相关知识或者验证知识;(3)当系统中知识不完整,如实体缺失,则请求用户给出这部分的知识并保存.

5 开放领域对话系统的评测

对话系统的质量需要有合理的度量标准来评价. 好的评价标准能指引系统发展的方向,把握技术的进展. 任务导向的对话系统可以根据人工给定的有监督信号来进行评估,例如任务完成测试^[17]等. 但是开放领域对话系统的回复具有多样性等特点,自动评估仍然是尚未解决的问题. 一般来说,性能良好的开放领域对话系统需要具备语义相关度高、信息量丰富、表达方式多样的特点. 具体到不同的实现方法,评测考量指标也有差异,下面分类进行介绍.

当前开放领域对话系统的评价方法有两种思路,一种是人工评测,一种是客观地自动评价指标. 详细分类如图 28 所示.




图 28 开放领域对话系统评测方法分类

5.1 人工评测

人工评测是指通过测试人员人工对测试结果进行评测。

三级评分指标. 一些研究采用三级人工评测的方法^[25,72,101]. 该方法邀请多个评测者对生成的测试回复进行打分,根据回复质量分为三级: +2,表示与对话上文相比回复语句很自然且语义相关; +1,回复可以是查询正确的回应,但是包含的信息非常少. 例如“我不知道”,“我不确定”等; 0,回应无关紧要,无意义,或者有严重的语法错误.

成对对比指标. 该方法直接将两个模型的回复作比较选择更好的一个^[82]. Chen 等人^[85]要求打分者从回复的恰当性和包含的信息量两个维度分别选出表现更好的一个.

5.2 不可学习的评测指标

5.2.1 检索模型评测指标

在检索式对话系统中,候选答案的排序是这类系统的核心,一般使用传统信息检索系统的常用评测指标. 早期包括准确率(Precision)、召回率(Recall)、F1 值等.

(1) 召回率 = 系统检索到的相关回复 / 系统所有相关的回复总数

(2) 准确率 = 系统检索到的相关回复 / 系统所有检索到的回复总数

召回率考察系统找全回复的能力,而准确率考察系统找准回复的能力,两者相辅相成,从两个不同侧面较为全面地反映系统性能. F1 值是召回率和准确率的调和平均数.

$$F1 = 2 \frac{precision \cdot recall}{precision + recall} \tag{1}$$

随着测试集规模的扩大以及人们对评测结果理解的深入,研究者提出能更准确反映系统性能的新评价指标,包括:

(1) 平均准确率 MAP(Mean Average Precision): AP(Average Precision)是指单个查询检索的平均精确度,MAP 是对整个测试集求平均 AP 值.

$$MAP = \frac{1}{|Q_R|} \sum_{q \in Q_R} AP(q) \tag{2}$$

(2) *R-Precision*: 单个查询的 *R-Precision* 是检索出 *R* 个回复时的准确率. 其中 *R* 是测试集中与查询相关的回复.

(3) *P@10*: 是系统对于该查询返回的前 10 个结果的准确率.

5.2.2 生成模型评测指标

(1) 不需要参考回复的评测指标

① 困惑度(Perplexity)^[27]. 语言模型中通常用困惑度来衡量一句话出现的概率,也常常被用在对话生成评测中,评价生成回复语句的语言质量. 其基本思想是测试生成的回复语言质量越高,困惑度越小,越接近人类正常说话,模型越好. 困惑度指标的缺点是不能评估在对话中回复与上文的相关性.

② 熵(Entropy). 熵可以度量生成的回复的信息量^[82, 123].

③ 回复多样性指标 Distinct-1&2: 针对对话系统中万能回复的问题, Li 等人^[88]提出通过计算生成回复中 1 元词和 2 元词的比例来衡量回复的多样性. 具体来说, Distinct-1 和 Distinct-2 分别是不同的 unigrams 和 bigrams 的数量除以生成的单词总数.

④ 平均回复长度. 文献^[81, 123]用平均长度来衡量对话生成效果,认为生成长句子的模型相对质量更高.

(2) 基于词语重叠的方法

① BLEU 指标^[128]. 根据 *n* 元词($n=1, \dots, 4$)的准确率计算几何平均来衡量生成回复与真实回复的相似度. 这个指标最早是在机器翻译任务中使用, Serban 等人^[21]等都用到它来对生成式对话系统进行评分. 然而,它的有效性受到 Galley 等人^[129]的质疑并提出了可以考虑多个回复的 deltaBLEU 指标,然而现实中很难获得多个参考回复.

② ROUGE 指标^[130]. 是一种衡量 *N*-gram 的召回率的评测方法,也是基于词语重叠程度来衡量生

成语句的质量,主要用于文本摘要任务的评测.与 N -gram 不同,ROUGE 指标中的子串不必连续.它基于生成回复和真实回复的最长公共子序列的召回率计算.最长公共子序列是指在两句话中都按相同次序出现的一组词序列.

③ METEOR 指标^[131].该指标加入了生成回复和真实回复之间的对齐关系.使用 WordNet 计算特定的序列匹配、同义词、词根、词缀、释义之间的匹配关系,改善 BLEU 效果,使其跟人工判别共更强的相关性.同样也是使用 F -measure 的计算方法.

尽管 BLEU、METEOR、ROUGE 等词汇重叠评测方法已经被广泛的应用到生成式对话系统,但是 Liu 等人^[132]发现,这些评测方法仍然跟人类判断之间的相关性很弱.相比之下,BLEU 指标的效果要好于 ROUGE 和 METEOR,但也仅限于在 Twitter 语料库上表现出与人类判断之间很弱的相关性,在技术领域 Ubuntu 对话语料库则几乎没有相关性.其中,BLEU-2 指标的效果要好于 BLEU-3/4.

(3) 基于词向量的方法

上面的词重叠评价指标基本上都是用 N -gram 计算生成回复和真实回复之间的重合程度.而 Liu 等人^[132]提出了基于词向量的评价指标,通过 Word2Vec、Sent2Vec 等方法将句子转换为语义向量表示,再通过余弦相似度等方法就计算生成回复和真实回复之间的语义相似程度.相比词重叠要求出现完全相同 N -gram 的条件,词向量方法的限制降低很多,可以基于词向量计算大多数词语对相似度,再设计算法计算生成回复和参考回复之间的相似性.后来一些研究使到该指标进行评测^[85].具体如下:

① 贪婪匹配 (Greedy Matching). 如式 (3) 和式 (4) 所示,对于真实回复的每个词,寻找其在生成回复中词向量相似度最高的词,并将其余弦相似度相加并求平均.同样再对生成回复再做一遍,并取二者的平均值.该指标主要关注两句话之间最相似的词语.

$$G(\mathbf{r}, \hat{\mathbf{r}}) = \frac{\sum_{w \in \mathbf{r}} \max_{\hat{w} \in \hat{\mathbf{r}}} \cos_sim(\mathbf{e}_w, \mathbf{e}_{\hat{w}})}{|\mathbf{r}|} \quad (3)$$

$$GM(\mathbf{r}, \hat{\mathbf{r}}) = \frac{G(\mathbf{r}, \hat{\mathbf{r}}) + G(\hat{\mathbf{r}}, \mathbf{r})}{2} \quad (4)$$

② 平均匹配 (Embedding Average). 这种方法直接使用句向量计算真实回复和生成回复之间的余弦相似度.句向量是句子包含的词向量的加和平均,

如式 (5) 和 (6) 所示.

$$\bar{\mathbf{e}}_r = \frac{\sum_{w \in \mathbf{r}} \mathbf{e}_w}{\left| \sum_{w \in \mathbf{r}} \mathbf{e}'_w \right|} \quad (5)$$

$$EA := \cos(\bar{\mathbf{e}}_r, \bar{\mathbf{e}}_{\hat{r}}) \quad (6)$$

③ 向量极值 (Vector Extrema). 这种方法需获取向量的极值.具体来说,对于词向量的每一个维度,取其最大值和最小值来作为句子向量的该维度表示,详见式 (7).

$$e_{rd} = \begin{cases} \max_{w \in \mathbf{r}} e_{wd}, & e_{wd} > \left| \min_{w' \in \mathbf{r}} e_{w'd} \right| \\ \min_{w \in \mathbf{r}} e_{wd}, & \text{其他} \end{cases} \quad (7)$$

其中, d 是向量的维度; e_{wd} 表示 w 的词向量 $\mathbf{e}_w$ 的第 d 维的值.由于词向量值可能是正也可能是负的,公式中的 $\min$ 函数意思就是:如果最小负值的绝对值大于最大的正值时,则取负值.通过沿着每个维度取极值,可以忽略常见词汇,重要语义信息的词会保留.

5.3 可学习的评测指标

不可学习的评测方法仅利用生成回复自身的特征或信息量来进行评测,没有结合对话上下文语境.最近,一些研究针对对话系统提出监督学习的评测方法,训练神经网络评价模型来实现对开放领域对话系统的评价.

5.3.1 监督学习

① ADEM^[133].该方法需预先收集对话语料的人工评分,并使用层次循环神经网络训练自动对话评估模型,目标是预测人工评分.计算评分的公式如式 (8),其中, $\mathbf{c}$ 是对话上下文的向量表示, $\mathbf{r}$ 是参考回复的向量表示, $\hat{\mathbf{r}}$ 是模型生成回复的向量表示. $\mathbf{M}$ 和 $\mathbf{N}$ 是参数矩阵, α 和 β 是在 $[0, 5]$ 范围内初始化的标量常量.矩阵 $\mathbf{M}$ 和 $\mathbf{N}$ 可以理解为将上下文 $\mathbf{c}$ 和参考回复 $\mathbf{r}$ 投影到可与生成回复 $\hat{\mathbf{r}}$ 直接比较的表示空间,最终的目的是训练出 $\mathbf{M}$ 和 $\mathbf{N}$,目标函数是使得模型预测得分与人类评分的误差最小. ADEM 评价模型需要大量的人工标注的分数作为训练数据,因此不宜扩展.

$$\text{score}(\mathbf{c}, \mathbf{r}, \hat{\mathbf{r}}) = (\mathbf{c}^T \mathbf{M} \hat{\mathbf{r}} + \mathbf{r}^T \mathbf{N} \hat{\mathbf{r}} - \alpha) / \beta \quad (8)$$

② RUBER^[134]. RUBER 指标也是基于监督式学习的方法,同样结合对话上下文和参考回复建立评价模型.具体来说,该方法将有参考的指标和无参考的指标想结合来评价对话回复:有参考的指标指通过词向量来计算回复和真实回复之间的相似度;无参考的指标用最大边际目标函数训练回复和查询

之间的相关性. 与 ADEM 相比, RUBER 评价指标的训练不需要人工评价标签, 更为灵活并且易于扩展到不同的数据集和语言. RUBER 在检索和生成式对话系统上都进行了实验, 结果表明 RUBER 与人工评价具有很高的相关性.

5.3.2 对抗学习

最早将对抗学习的思想用于自然语言处理技术评估是 Bowman 等人^[135], 他们训练一个判别器来区分系统生成的句子和真实句子. 借用图灵测试的思路, Kannan 等人^[136]在生成式对话系统中初步研究对抗评估的方法. 其主要思路是训练评估系统来代替人工评估员来区分人类回复和系统生成回复, 再用这个评估系统来评估生成回复的质量. Xu 等人^[76]在基于生成对抗网络建立对话系统模型时也建立了一个回复质量的判别器. Tong 等人^[137]对监督学习的 RUBER 指标做改进, 基于对抗性的多任务学习框架建立了一个多语言对话的评估模型, 使得不同的语言可以同时建立评估模型, 并促进跨语言的知识共享.

6 基于深度学习的开放领域对话系统研究趋势展望

随着技术的发展, 深度学习在自然语言处理领域被越来越多地研究. 基于深度学习的开放领域对话系统已经成为当前的研究热点. 但是, 由于研究时间较短, 深度学习技术在开放领域对话系统中的应用尚处于起步阶段, 检索式方法和生成式方法都还不能模拟或者代替人类对话, 许多关键性问题值得深入探索. 本文总结以下 7 个研究方向.

(1) 基于深度学习提高开放领域对话系统的情感拟人程度. 数据驱动的开放领域对话系统着重关注建立查询和回复的语义对应关系. 而现实中, 人类真实对话还会受到情感等方面的影响, 虽然目前已有相关研究出现, 但是拟人程度还远远不够. 深度学习技术在情感分析领域已经取得了一定成果, 可以将其引入来精准识别用户情绪(积极正面、消极负面等), 并根据不同的情感类型给出相应拟人的回应. 例如, 当输入查询的情绪为消极负面情绪时, 系统给出安抚回复, 当话题陷入沉闷无趣时, 则给出具有幽默感和有趣的回复. 还可以探索基于强化学习框架建立带在线反馈机制的交互式情感引导对话模型. 总的来说, 基于深度学习模型来实现情感拟人程度更高的开放领域对话系统将是未来可研究的方向.

(2) 基于深度学习控制开放领域对话系统的回复逻辑. 对话逻辑问题是当前对话系统实现的难点. 一方面人类对话常常包含常识的推理和演绎, 目前的系统尚未对其建模. 另一方面, 数据驱动的开放领域对话系统以对话语料库为基础给出查询概率最大的回复, 无法保证回复逻辑一致. 这个问题在生成式开放领域对话系统中尤其突出. 当前, 基于深度学习技术的阅读理解任务已对文本内容推理过程建模, 取得了初步研究成果. 未来, 可以尝试用深度学习技术对话逻辑推理建模, 并整合到根据查询输出回复的过程中.

(3) 基于深度学习主动把握开放领域对话系统的对话节奏. 当前的开放领域对话系统以被动的回应为主. 而真实的对话场景下, 对话节奏通常由对话双方共同把握. 虽然已有一些研究尝试通过对话建议和内容引导的方式, 引入新的内容, 但还远不能满足把握对话节奏的要求. 未来, 可以继续研究基于深度学习技术的内容引导和节奏把控方法. 一方面, 可以考虑将当前的一步式引导拓展到多步引导, 以更加平缓的方式引导新内容, 使得对话节奏转换更加自然. 另一方面, 可以在内容引导的框架下探索考虑对话双方的互动, 预测对话趋势, 更有效地掌控对话节奏.

(4) 基于深度学习建立更合理的对话评价机制. 合理的开放领域对话系统的评价指标对于持续提升系统性能至关重要, 能让研究工作目标明确, 并有针对性地设计技术方案进行改进. 检索式对话系统通常假设只有一个正确的回复, 即使给出的回复与正确回复相似也会被视为是错误回复. 尤其在多轮对话的评测中, 完全匹配的限制过于严格, 不符合对话实际. 生成式对话系统则主要延续机器翻译的评测方法, 即通过计算系统生成回复和参考回复之间的差距来衡量生成回复的质量. 然而, 对话系统和机器翻译不一样, 由于对话的多样性特点, 单凭一个或有限个标准回复去衡量生成回复的设定不充分也不合理. 还有很多工作通过人工评测来进行效果评价, 代价大且不易标准化. 目前已有一些基于监督学习的评价系统, 但其通用性或者与人工评价的相关性仍有待改进. 未来应继续深入研究开放领域对话系统的评测方法, 探索更先进的深度学习模型, 建立更合理的评测机制.

(5) 通过深度学习模型将检索式和生成式方法更好的整合. 检索式和生成式对话模型原理不同, 实现技术不同, 各有优缺点, 却有相同的目标. 检索

式方法能给出更流畅的、更符合逻辑的回复,生成式则能够对更复杂的语境建模,例如情感、个性化等。现在已经少数研究将两种方法相结合,提升对话整体效果。未来,随着深度学习技术的发展,可以尝试研究更多的组合机制,相信会给开放领域对话系统带来更大的突破。

(6) 使用数据增强技术构建高质量的基准对话数据集。对于深度学习模型来讲,训练数据的不断增加能够带来性能的提升。然而,在开放领域对话系统中,对话数据集大多从社交网络中收集,不可避免地存在大量错误和噪音,高质量的对话数据相对缺乏。数据增强技术已经在图像处理领域取成功,在自然语言处理领域还没有被深入探索。研究自然语言的数据增强技术,并将其应用到开放领域对话系统中,构造优质、大规模的基准对话数据集是未来可以努力的方向。

(7) 使用深度学习技术构建多模态的开放领域对话系统。现实中,社交网络的人人对话常常混合使用各种类型的数据进行交互,即语音、图像、文本常常混合使用。当前,深度学习技术在语音、图像、文本单独领域的应用研究较多,取得了一定的成果,但将这些技术综合应用的多模态技术还有待深入研究。为了将对话系统投入实际使用,发挥有效价值,建立基于多模态的开放领域对话系统也是当前工业界关注的方向。

7 结束语

人机对话系统作为下一代人机交互的服务模式,受到工业界和学术界的广泛关注。深度学习技术的发展和对话数据在互联网上的积累,也为数据驱动的开放领域对话系统带来了机遇。根据是否考虑历史对话信息,开放领域对话系统分为单轮对话系统和多轮对话系统。根据系统实现方法,基于深度学习的开放领域对话系统可分为检索式模型、生成式模型及二者相结合的模型。本文主要围绕基于深度学习技术的开放领域对话系统进行介绍,分类梳理已有的研究成果,整理关键问题及已有的解决方案,总结开放领域对话系统的评测指标,尝试为研究人员建立一个较完整的领域研究视图,希望能对相关领域的研究者提供帮助。

致谢 在此,我们向对本文的工作给予支持和建议的同行表示衷心的感谢!

参 考 文 献

- [1] Turing A M. I.—Computing machinery and intelligence. *Mind*, 1950, LIX(236): 433-460
- [2] Yan R. “Chitty-chitty-chat bot”: Deep learning for conversational AI//*Proceedings of the International Joint Conference on Artificial Intelligence*. Stockholm, Sweden, 2018: 5520-5526
- [3] Chen H, Liu X, Yin D, Tang J. A survey on dialogue systems: Recent advances and new frontiers. *ACM Special Interest Group on Knowledge Discovery and Data Mining (SIGKDD) Explorations*, 2017, 19(2): 25-35
- [4] Weizenbaum J. ELIZA—A computer program for the study of natural language communication between man and machine. *Communications of the ACM*, 1966, 9(1): 36-45
- [5] Wilensky R, Chin D N, Luria M, et al. The Berkeley UNIX consultant project. *Computational Linguistics*, 1988, 14(4): 35-84
- [6] Wallace R S. The anatomy of A. L. I. C. E//Epstein R, Roberts G, Beber G eds. *Parsing the Turing Test: Philosophical and Methodological Issues in the Quest for the Thinking Computer*. Netherlands: Springer, 2009: 181-210
- [7] Marietto M D G B, De Aguiar R V, Barbosa G D O, et al. Artificial intelligence markup language: A brief tutorial. *arXiv preprint arXiv: 1307.3091*, 2013
- [8] Nakano M, Miyazaki N, Yasuda N, et al. WIT: A toolkit for building robust and real-time spoken dialogue systems//*Proceedings of the Annual Meeting of the Special Interest Group on Discourse and Dialogue*. Hong Kong, China, 2000: 150-159
- [9] Leuski A, Traum D R. NPCEditor: Creating virtual human dialogue using information retrieval techniques. *Innovative Applications of Artificial Intelligence*, 2011, 32(2): 42-56
- [10] Serban I V, Lowe R, Henderson P, et al. A survey of available corpora for building data-driven dialogue systems. *arXiv preprint arXiv:1512.05742*, 2015
- [11] Serban I V, Lowe R, Charlin L, Pineau J. Generative deep neural networks for dialogue: A short review. *arXiv preprint arXiv:1611.06216*, 2016
- [12] Shang L, Lu Z, Li H. Neural responding machine for short-text conversation//*Proceedings of the International Joint Conference on Natural Language Processing*. Beijing, China, 2015: 1577-1586
- [13] Zhang Wei-Nan, Zhang Yang-Zi, Liu Ting. Survey of evaluation methods for dialogue systems. *Science China: Scientia Sinica information*, 2017, 47(8): 953-966(in Chinese)
(张伟男, 张杨子, 刘挺. 对话系统评价方法综述. *中国科学: 信息科学*, 2017, 47(8): 953-966)
- [14] Luong T, Pham H, Manning C D. Effective approaches to attention-based neural machine translation//*Proceedings of the Empirical Methods in Natural Language Processing*. Lisbon, Portugal, 2015: 1412-1421

- [15] Godfrey J J, Holliman E, McDaniel J. Switchboard: Telephone speech corpus for research and development//Proceedings of the International Conference on Acoustics, Speech, and Signal Processing. San Francisco, USA, 1992: 517-520
- [16] Kim S, Dhano L F, Banchs R E, et al. The fifth dialog state tracking challenge//Proceedings of the Spoken Language Technology Workshop. San Diego, USA, 2016: 511-517
- [17] Kim S, D'Haro L F, Banchs R E, et al. The fourth dialog state tracking challenge. *AI Magazine*, 2017, 35(4): 121-124
- [18] Danescuiculescuzil C, Lee L. Chameleons in imagined conversations: A new approach to understanding coordination of linguistic style in dialogs//Proceedings of the Meeting of the Association for Computational Linguistics. Portland, USA, 2011: 76-87
- [19] Tiedemann J. News from OPUS — A collection of multilingual parallel corpora with tools and interfaces. *Recent Advances in Natural Language Processing*, 2009, 5: 237-248
- [20] Ritter A, Cherry C, Dolan B. Unsupervised modeling of Twitter conversations//Proceedings of the North American Chapter of the Association for Computational Linguistics. Los Angeles, USA, 2010: 172-180
- [21] Sordani A, Galley M, Auli M, et al. A neural network approach to context-sensitive generation of conversational responses//Proceedings of the North American Chapter of the Association for Computational Linguistics. Denver, USA, 2015: 196-205
- [22] Higashinaka R, Kobayashi N, Hirano T, et al. Syntactic filtering and content-based retrieval of Twitter sentences for the generation of system utterances in dialogue systems//Rudnicki A, Raux A, Lane I eds. *Situated Dialog in Speech-Based Human-Computer Interaction*. Cham, Switzerland: Springer International Publishing, 2016: 15-26
- [23] Uthus D C, Aha D W. The Ubuntu chat corpus for multiparticipant chat analysis//Proceedings of the 2013 National Conference on Artificial Intelligence (AAAI) Spring Symposium Series: Analyzing Microtext. 2013
- [24] Lowe R, Pow N, Serban I V, Pineau J. The Ubuntu dialogue corpus: A large dataset for research in unstructured multi-turn dialogue systems//Proceedings of the Annual Meeting of the Special Interest Group on Discourse and Dialogue. Prague, Czech Republic, 2015: 285-294
- [25] Song Y, Yan R, Li X, et al. Two are better than one: An ensemble of retrieval- and generation-based dialog systems. *arXiv preprint arXiv:1610.07149*, 2016
- [26] LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*, 2015, 521(7553): 436
- [27] Bengio Y, Ducharme R, Vincent P, Janvin C. A neural probabilistic language model. *Journal of Machine Learning Research*, 2003, 3(6): 1137-1155
- [28] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors. *Nature*, 1988, 323(6088): 696-699
- [29] Hinton G E, Osindero S, Teh Y W. A fast learning algorithm for deep belief nets. *Neural Computation*, 2006, 18(7): 1527-1554
- [30] Bengio Y, Lamblin P, Popovici D, Larochelle H. Greedy layer-wise training of deep networks//Proceedings of the Neural Information Processing Systems. Vancouver, Canada, 2006: 153-160
- [31] Doersch C. Tutorial on variational autoencoders. *arXiv preprint arXiv:1606.05908*, 2016
- [32] Hu B, Lu Z, Li H, Chen Q. Convolutional neural network architectures for matching natural language sentences//Proceedings of the Neural Information Processing Systems. Montreal, Canada, 2014: 2042-2050
- [33] Kim Y. Convolutional neural networks for sentence classification. *arXiv preprint arXiv:1408.5882*, 2014
- [34] Lipton Z C. A critical review of recurrent neural networks for sequence learning. *arXiv preprint arXiv:1506.00019*, 2015
- [35] Hochreiter S, Schmidhuber J. Long short-term memory. *Neural Computation*, 1997, 9(8): 1735-1780
- [36] Cho K, Van Merriënboer B, Bahdanau D, Bengio Y. On the properties of neural machine translation: Encoder-decoder approaches//Proceedings of the Empirical Methods in Natural Language Processing. Doha, Qatar, 2014: 103-111
- [37] Cho K, Van Merriënboer B, Gulcehre C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation//Proceedings of the Empirical Methods in Natural Language Processing. Doha, Qatar, 2014: 1724-1734
- [38] Sutskever I, Vinyals O, Le Q V. Sequence to sequence learning with neural networks//Proceedings of the Neural Information Processing Systems. Montreal, Canada, 2014: 3104-3112
- [39] Bahdanau D, Cho K, Bengio Y. Neural machine translation by jointly learning to align and translate. *arXiv preprint arXiv:1409.0473*, 2014
- [40] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need//Proceedings of the Neural Information Processing Systems. Long Beach, USA, 2017: 5998-6008
- [41] Weston J, Chopra S, Bordes A. Memory networks. *arXiv preprint arXiv:1410.3916*, 2014
- [42] Sukhbaatar S, Szlam A, Weston J, Fergus R. End-to-end memory networks//Proceedings of the Neural Information Processing Systems. Montreal, Canada, 2015: 2440-2448
- [43] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets//Proceedings of the Neural Information Processing Systems. Montreal, Canada, 2014: 2672-2680
- [44] Sutton R S, Barto A G. *Introduction to reinforcement learning*. MIT Press, 1998
- [45] Mnih V, Kavukcuoglu K, Silver D, et al. Playing Atari with deep reinforcement learning. *arXiv preprint arXiv:1312.5602*, 2013

- [46] Sutton R S, Mcallester D A, Singh S P, Mansour Y. Policy gradient methods for reinforcement learning with function approximation//Proceedings of the Neural Information Processing Systems, Denver, USA, 1999: 1057-1063
- [47] Guo J, Fan Y, Ai Q, Croft W B. A deep relevance matching model for ad-hoc retrieval//Proceedings of the International Conference on Information and Knowledge Management, Indianapolis, USA, 2016: 55-64
- [48] Shen Y, He X, Gao J, et al. Learning semantic representations using convolutional neural networks for Web search//Proceedings of the International World Wide Web Conferences, Seoul, Korea, 2014: 373-374
- [49] Wan S, Lan Y, Guo J, et al. A deep architecture for semantic matching with multiple positional sentence representations//Proceedings of the National Conference on Artificial Intelligence, Phoenix, USA, 2016: 2835-2841
- [50] Tan M, Santos C N D, Xiang B, Zhou B. Improved representation learning for question answer matching//Proceedings of the Meeting of the Association for Computational Linguistics, Berlin, Germany, 2016: 464-473
- [51] Yin W, Schutze H, Xiang B, Zhou B. ABCNN: Attention-based convolutional neural network for modeling sentence pairs. Transactions of the Association for Computational Linguistics, 2016, 4(1): 259-272
- [52] Kim S, Hong J H, Kang I, Kwak N. Semantic sentence matching with densely-connected recurrent and co-attentive information. arXiv preprint arXiv:1805.11360, 2018
- [53] Lu Z, Li H. A deep architecture for matching short texts//Proceedings of the Neural Information Processing Systems, Lake Tahoe, USA, 2013: 1367-1375
- [54] Pang L, Lan Y, Guo J, et al. Text matching as image recognition//Proceedings of the National Conference on Artificial Intelligence, Phoenix, USA, 2016: 2793-2799
- [55] Liu P, Qiu X, Chen J, Huang X. Deep fusion LSTMs for text semantic matching//Proceedings of the Meeting of the Association for Computational Linguistics, Berlin, Germany, 2016: 1034-1043
- [56] Wang Z, Hamza W, Florian R. Bilateral multi-perspective matching for natural language sentences//Proceedings of the International Joint Conference on Artificial Intelligence, Melbourne, Australia, 2017: 4144-4150
- [57] Wan S, Lan Y, Xu J, et al. Match-SRNN: Modeling the recursive matching structure with spatial RNN//Proceedings of the International Joint Conference on Artificial Intelligence, New York, USA, 2016: 2922-2928
- [58] Mitra B, Diaz F, Craswell N. Learning to match using local and distributed representations of text for Web search//Proceedings of the International World Wide Web Conferences, Perth, Australia, 2017: 1291-1299
- [59] Yu J, Qiu M, Jiang J, et al. Modelling domain relationships for transfer learning on retrieval-based question answering systems in e-commerce//Proceedings of the Web Search and Data Mining, Marina Del Rey, USA, 2018: 682-690
- [60] Huang G, Liu Z, Der Maaten L V, Weinberger K Q. Densely connected convolutional networks//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, USA, 2017: 2261-2269
- [61] Inaba M, Takahashi K. Neural utterance ranking model for conversational dialogue systems//Proceedings of the Annual Meeting of the Special Interest Group on Discourse and Dialogue, Los Angeles, USA, 2016: 393-403
- [62] Zhou X, Dong D, Wu H, et al. Multi-view response selection for human-computer conversation//Proceedings of the Empirical Methods in Natural Language Processing, Austin, USA, 2016: 372-381
- [63] Yan R, Song Y, Wu H. Learning to respond with deep neural networks for retrieval-based human-computer conversation system//Proceedings of the International ACM SIGIR Conference on Research and Development in Information Retrieval, Pisa, Italy, 2016: 55-64
- [64] Wu Y, Wu W, Xing C, et al. Sequential matching network: A new architecture for multi-turn response selection in retrieval-based Chatbots//Proceedings of the Meeting of the Association for Computational Linguistics, Vancouver, Canada, 2017: 496-505
- [65] Zhang Z, Li J, Zhu P, et al. Modeling multi-turn conversation with deep utterance aggregation//Proceedings of the International Conference on Computational Linguistics, Santa Fe, USA, 2018: 3740-3752
- [66] Zhou X, Li L, Dong D, et al. Multi-turn response selection for Chatbots with deep attention matching network//Proceedings of the Meeting of the Association for Computational Linguistics, Melbourne, Australia, 2018: 1118-1127
- [67] Yan R, Song Y, Zhou X, Wu H. "Shall I be your chat companion?": Towards an online human-computer conversation system//Proceedings of the International Conference on Information and Knowledge Management, Indianapolis, USA, 2016: 649-658
- [68] Zens R, Och F J, Ney H. Phrase-based statistical machine translation//Proceedings of the German Conference on AI: Advances in Artificial Intelligence, Berlin, Germany, 2002: 18-32
- [69] Ritter A, Cherry C, Dolan W B. Data-driven response generation in social media//Proceedings of the Empirical Methods in Natural Language Processing, Edinburgh, UK, 2011: 583-593
- [70] Shao L, Gouws S, Britz D, et al. Generating high-quality and informative conversation responses with sequence-to-sequence models//Proceedings of the Empirical Methods in Natural Language Processing, Copenhagen, Denmark, 2017: 2210-2219
- [71] Wang W, Huang M, Xu X, et al. Chat more: Deepening and widening the chatting topic via a deep model//Proceedings of the International ACM SIGIR Conference on Research and Development in Information Retrieval, Ann Arbor, USA, 2018: 255-264

- [72] Wu Y, Wu W, Li Z, et al. Neural response generation with dynamic vocabularies//Proceedings of the National Conference on Artificial Intelligence. New Orleans, USA, 2018: 5594-5601
- [73] Shang M, Fu Z, Peng N, et al. Learning to converse with noisy data: Generation with calibration//Proceedings of the International Joint Conference on Artificial Intelligence. Stockholm, Sweden, 2018: 4338-4344
- [74] Mei H, Bansal M, Walter M R. Coherent dialogue with attention-based language models//Proceedings of the National Conference on Artificial Intelligence. Phoenix, USA, 2016: 3252-3258
- [75] Li J, Monroe W, Ritter A, et al. Deep reinforcement learning for dialogue generation//Proceedings of the Empirical Methods in Natural Language Processing. Austin, USA, 2016: 1192-1202
- [76] Li J, Monroe W, Shi T, et al. Adversarial learning for neural dialogue generation//Proceedings of the Empirical Methods in Natural Language Processing. Copenhagen, Denmark, 2017: 2157-2169
- [77] Xu Z, Liu B, Wang B, et al. Neural response generation via GAN with an approximate embedding layer//Proceedings of the Empirical Methods in Natural Language Processing. Copenhagen, Denmark, 2017: 617-626
- [78] Vinyals O, Le Q V. A neural conversational model. arXiv preprint arXiv:1506.05869, 2015
- [79] Yao K, Zweig G, Peng B. Attention with intention for a neural network conversation model. arXiv preprint arXiv:1510.08565, 2015
- [80] Yan R, Zhao D. Smarter response with proactive suggestion: A new generative neural conversation paradigm//Proceedings of the International Joint Conference on Artificial Intelligence. Stockholm, Sweden, 2018: 4525-4531
- [81] Serban I V, Sordoni A, Bengio Y, et al. Building end-to-end dialogue systems using generative hierarchical neural network models//Proceedings of the National Conference on Artificial Intelligence. Phoenix, USA, 2016: 3776-3783
- [82] Serban I V, Sordoni A, Lowe R, et al. A hierarchical latent variable encoder-decoder model for generating dialogues//Proceedings of the National Conference on Artificial Intelligence. San Francisco, USA, 2017: 3295-3301
- [83] Serban I V, Klinger T, Tesauro G, Talamadupula K, Zhou B, Bengio Y, Courville A. C. Multiresolution recurrent neural networks: An application to dialogue response generation //Proceedings of the National Conference on Artificial Intelligence. Phoenix, USA, 2016: 3288-3294
- [84] Tian Z, Yan R, Mou L, Song Y, Feng Y, Zhao D. How to make context more useful? An empirical study on context-aware neural conversational models//Proceedings of the Meeting of the Association for Computational Linguistics. Vancouver, Canada, 2017: 231-236
- [85] Chen H, Ren Z, Tang J, Zhao Y. E. Yin D. Hierarchical variational memory network for dialogue generation//Proceedings of the International World Wide Web Conferences. Lyon, France, 2018: 1653-1662
- [86] Li J, Luong T, Jurafsky D. A hierarchical neural autoencoder for paragraphs and documents//Proceedings of the International Joint Conference on Natural Language Processing. Beijing, China, 2015: 1106-1115
- [87] Kingma D. P., Welling M. Auto-encoding variational bayes. arXiv preprint arXiv:1312.6114, 2013
- [88] Li J, Galley M, Brockett C, Gao J, Dolan B. A diversity-promoting objective function for neural conversation models//Proceedings of the North American Chapter of the Association for Computational Linguistics. San Diego, USA, 2016: 110-119
- [89] Qiu M, Li F, Wang S, et al. AliMe Chat: A sequence to sequence and rerank based chatbot engine//Proceedings of the Meeting of the Association for Computational Linguistics. Vancouver, Canada, 2017: 498-503
- [90] Vijayakumar A K, Cogswell M, Selvaraju R R, et al. Diverse beam search: Decoding diverse solutions from neural sequence models. arXiv preprint arXiv:1610.02424, 2016
- [91] Li J, Monroe W, Jurafsky D. A simple, fast diverse decoding algorithm for neural generation. arXiv preprint arXiv:1611.08562, 2016
- [92] Yao K, Peng B, Zweig G, Wong K. An attentional neural conversation model with improved specificity. arXiv preprint arXiv:1606.01292, 2016
- [93] Song Y, Tian Z, Zhao D, et al. Diversifying neural conversation model with maximal marginal relevance//Proceedings of the International Joint Conference on Natural Language Processing. Taipei, China, 2017: 169-174
- [94] Cao K, Clark S. Latent variable dialogue models and their diversity//Proceedings of the Conference of the European Chapter of the Association for Computational Linguistics. Valencia, Spain, 2017: 182-187
- [95] Shen X, Su H, Li Y, et al. A conditional variational framework for dialog generation//Proceedings of the Meeting of the Association for Computational Linguistics. Vancouver, Canada, 2017: 504-509
- [96] Zhou G, Luo P, Cao R, et al. Mechanism-aware neural machine for dialogue response generation//Proceedings of the National Conference on Artificial Intelligence. San Francisco, USA, 2017: 3400-3407
- [97] Zhao T, Zhao R, Eskenazi M. Learning discourse-level diversity for neural dialog models using conditional variational autoencoders//Proceedings of the Meeting of the Association for Computational Linguistics. Vancouver, Canada, 2017: 654-664
- [98] Tao C, Gao S, Shang M, et al. Get the point of my utterance! Learning towards effective responses with multi-head attention mechanism//Proceedings of the International Joint Conference on Artificial Intelligence. Stockholm, Sweden, 2018: 4418-4424
- [99] Song Y, Yan R, Feng Y, et al. Towards a neural conversation model with diversity net using determinantal point processes //Proceedings of the National Conference on Artificial Intelligence. New Orleans, USA, 2018: 5932-5939

- [100] Wu Y, Li Z, Wu W, Zhou M. Response selection with topic clues for retrieval-based Chatbots. *Neurocomputing*, 2018, 316: 251-261
- [101] Xing C, Wu W, Wu Y, et al. Topic aware neural response generation//*Proceedings of the National Conference on Artificial Intelligence*. San Francisco, USA, 2017: 3351-3357
- [102] Xing C, Wu W, Wu Y, et al. Topic augmented neural response generation with a joint attention mechanism. *arXiv preprint arXiv:1606.08340*, 2016
- [103] Choudhary S, Srivastava P, Ungar L H, Sedoc J. Domain aware neural dialog system. *arXiv preprint arXiv:1708.00897*, 2017
- [104] Lowe R, Pow N, Serban I, et al. Incorporating unstructured textual knowledge sources into neural dialogue systems//*Proceedings of the Neural Information Processing Systems Workshop on Machine Learning for Spoken Language Understanding*. Montreal, Canada, 2015
- [105] Young T, Cambria E, Chaturvedi I, et al. Augmenting end-to-end dialogue systems with commonsense knowledge //*Proceedings of the National Conference on Artificial Intelligence*. New Orleans, USA, 2018: 4970-4977
- [106] Yang L, Qiu M, Qu C, et al. Response ranking with deep matching networks and external knowledge in information-seeking conversation systems//*Proceedings of the International ACM SIGIR Conference on Research and Development in Information Retrieval*. Ann Arbor, USA, 2018: 245-254
- [107] Wu Y, Wu W, Li Z. Knowledge enhanced hybrid neural network for text matching//*Proceedings of the National Conference on Artificial Intelligence*. New Orleans, USA, 2018: 5586-5593
- [108] Zhu W, Mo K, Zhang Y, et al. Flexible end-to-end dialogue system for knowledge grounded conversation. *arXiv preprint arXiv:1709.04264*, 2017
- [109] Vougiouklis P, Hare J S, Simperl E. A neural network approach for knowledge-driven response generation//*Proceedings of the International Conference on Computational Linguistics*. Osaka, Japan, 2016: 3370-3380
- [110] Ghazvininejad M, Brockett C, Chang M, et al. A knowledge-grounded neural conversation model//*Proceedings of the National Conference on Artificial Intelligence*. New Orleans, USA, 2018: 5110-5117
- [111] Zhou H, Young T, Huang M, et al. Commonsense knowledge aware conversation generation with graph attention//*Proceedings of the International Joint Conference on Artificial Intelligence*. Stockholm, Sweden, 2018: 4623-4629
- [112] Zhou H, Huang M, Zhang T, et al. Emotional chatting machine: Emotional conversation generation with internal and external memory//*Proceedings of the National Conference on Artificial Intelligence*. New Orleans, USA, 2018: 730-739
- [113] Asghar N, Poupart P, Hoey J, et al. Affective neural response generation//*Proceedings of the European Conference on Information Retrieval*. Grenoble, France, 2018: 154-166
- [114] Zhou X, Wang W Y. MojiTalk: Generating emotional responses at scale//*Proceedings of the Meeting of the Association for Computational Linguistics*. Melbourne, Australia, 2018: 1128-1137
- [115] Zhang W, Zhu Q, Wang Y, et al. Neural personalized response generation as domain adaptation//*Proceedings of the International World Wide Web Conferences*. Lyon, France, 2018: 1-20
- [116] Li J, Galley M, Brockett C, et al. A persona-based neural conversation model//*Proceedings of the Meeting of the Association for Computational Linguistics*. Berlin, Germany, 2016: 994-1003
- [117] Engonopoulos N, Teichmann C, Koller A. Discovering user groups for natural language generation. *arXiv preprint arXiv:1806.05947*, 2018
- [118] Qian Q, Huang M, Zhao H, et al. Assigning personality/profile to a chatting machine for coherent conversation generation//*Proceedings of the International Joint Conference on Artificial Intelligence*. Stockholm, Sweden, 2018: 4279-4285
- [119] Li X, Mou L, Yan R, Zhang M. StalemateBreaker: A proactive content-introducing approach to automatic human-computer conversation//*Proceedings of the International Joint Conference on Artificial Intelligence*. New York, USA, 2016: 2845-2851
- [120] Yan R, Zhao D, Weinan E. Joint learning of response ranking and next utterance suggestion in human-computer conversation system//*Proceedings of the International ACM SIGIR Conference on Research and Development in Information Retrieval*. Tokyo, Japan, 2017: 685-694
- [121] Wen T, Gasic M, Mrksic N, et al. Semantically conditioned LSTM-based natural language generation for spoken dialogue systems//*Proceedings of the Empirical Methods in Natural Language Processing*. Lisbon, Portugal, 2015: 1711-1721
- [122] Xu Z, Liu B, Wang B, et al. Incorporating loose-structured knowledge into conversation modeling via recall-gate LSTM//*Proceedings of the International Symposium on Neural Networks*. Hokkaido, Japan, 2017: 3506-3513
- [123] Mou L, Song Y, Yan R, et al. Sequence to backward and forward sequences: A content-introducing approach to generative short-text conversation//*Proceedings of the International Conference on Computational Linguistics*. Osaka, Japan, 2016: 3349-3358
- [124] Yao L, Zhang Y, Feng Y, et al. Towards implicit content-introducing for generative short-text conversation systems//*Proceedings of the Empirical Methods in Natural Language Processing*. Copenhagen, Denmark, 2017: 2190-2199

- [125] Asghar N, Poupart P, Jiang X, Li H. Deep active learning for dialogue generation//Proceedings of the Joint Conference on Lexical and Computational Semantics. Vancouver, Canada, 2017; 78-83
- [126] Li J, Miller A H, Chopra S, et al. Dialogue learning with human-in-the-loop. arXiv preprint arXiv: 1611. 09823, 2016
- [127] Li J, Miller A H, Chopra S, et al. Learning through dialogue interactions by asking questions. arXiv preprint arXiv: 1612. 04936, 2016
- [128] Papineni K, Roukos S, Ward T, Zhu W. BLEU: A method for automatic evaluation of machine translation//Proceedings of the Meeting of the Association for Computational Linguistics. Philadelphia, USA, 2002; 311-318
- [129] Galley M, Brockett C, Sordoni A, et al. deltaBLEU: A discriminative metric for generation tasks with intrinsically diverse targets//Proceedings of the International Joint Conference on Natural Language Processing. Beijing, China, 2015; 445-450
- [130] Lin C, Hovy E H. Automatic evaluation of summaries using *N*-gram co-occurrence statistics//Proceedings of the North American Chapter of the Association for Computational Linguistics. Edmonton, Canada, 2003; 71-78
- [131] Lavie A, Agarwal A. METEOR: An automatic metric for MT evaluation with high levels of correlation with human judgments//Proceedings of the Workshop on Statistical Machine Translation. Prague, Czech Republic, 2007; 228-231
- [132] Liu C, 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//Proceedings of the Empirical Methods in Natural Language Processing. Austin, USA, 2016; 2122-2132
- [133] Lowe R, Noseworthy M, Serban I V, et al. Towards an automatic turing test: Learning to evaluate dialogue responses//Proceedings of the Meeting of the Association for Computational Linguistics. Vancouver, Canada, 2017; 1116-1126
- [134] Tao C, Mou L, Yan R, Zhao D. RUBER: An unsupervised method for automatic evaluation of open-domain dialog systems//Proceedings of the National Conference on Artificial Intelligence. New Orleans, USA, 2018; 722-729
- [135] Bowman S R, Vilnis L, Vinyals O, et al. Generating sentences from a continuous space//Proceedings of the Conference on Computational Natural Language Learning. Berlin, Germany, 2016; 10-21
- [136] Kannan A, Vinyals O. Adversarial evaluation of dialogue models. arXiv preprint arXiv:1701. 08198, 2017
- [137] Tong X, Fu Z, Shang M, et al. One “ruler” for all languages: Multi-lingual dialogue evaluation with adversarial multi-task learning//Proceedings of the International Joint Conference on Artificial Intelligence. Stockholm, Sweden, 2018; 4432-4438



CHEN Chen, Ph.D. candidate, assistant professor. Her main research interests focus on natural language processing.

ZHU Qing-Qing, Ph.D. candidate. Her main research interests focus on natural language processing.

YAN Rui, Ph.D., assistant professor. His main research interests focus on natural language processing.

LIU Jun-Fei, Ph.D., professor. His main research interests focus on software process.

Background

The human-machine dialogue system enables machines to interact with people through natural language, which is an important task in artificial intelligence. Because of its commercial value in the fields of virtual assistants and social Chatbots, it has been widely concerned by business and academia. Dialogue systems can be classified as domain-specific and open-domain models. Domain-specific dialogue systems accomplish a specific task, while open-domain dialogue systems do not limit the dialogue topic to a specific domain, and typically do not have a clear dialogue goal.

With the massive human-human conversation utterances available on the web, previous studies have developed data-

oriented approaches in the open domain, which can be roughly categorized into two groups: retrieval systems and generative systems. It is intuitive to build a retrieval based conversational system as information retrieval techniques are developing fast since 2003. Also, recent studies use generation-based methods by training a sequence-to-sequence neural network (Seq2Seq) to build open-domain dialogue systems. These models directly synthesize new sentences as responses according to the previous queries. In this survey, we summarize the problem formulation for Chatbots, and give an overview of state-of-the-art methods for open domain dialogue systems from several aspects.