

基于开放领域的人机对话系统综述

wdevin@qq.com

摘要：人机对话系统是自然语言处理领域中的重要问题之一，基于开放领域的非任务型对话系统因其在虚拟助手和聊天机器人等方面的商业价值而备受关注。近年来，由于互联网社交数据的快速增长，基于数据驱动的深度学习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，然后主要以开放领域人机对话系统为研究对象，按照不同的构建方法将其技术分为检索式、生成式和检索与生成相结合三大类，结合最近几年发表的文献对每类方法中所提出的经典模型进行概括、分析和比较。最后对人机对话系统的方法进行总结，并结合最新研究热点对未来的研究趋势进行展望。

关键词：对话系统；深度学习；序列到序列模型；强化学习

1 引言

自然语言作为人类在整个文明发展过程中产生的交流语言，是人类用来直接表达情感和分享信息的重要工具。让机器具备与人类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性的任务。早在 20 世纪 50 年代，图灵就提出利用人机对话来测试机器的智能水平。此后，学者们尝试利用各种方法研究和构建对话系统，期望打造出具有足够智慧的对话系统为人类生活的各个领域提供帮助，实现与人类的智能交互。

工业界将对话系统看作是人工智能时代人机交互的主要形式，近年来投入大量的人力和资源到相关研发工作中。基于对话系统的商业产品及应用不断涌现，有不少产品已进入量产阶段。按照应用场景的不同，对话系统一般可分为任务驱动型的限定领域对话系统和非任务型的开放领域对话系统。限定领域对话系统是为了完成特定任务而设计的，例如机票订购、地图导航等。开放领域对话系统也被称为聊天机器人，是无特定任务驱动而为了纯聊天或者娱乐而开发的。在限定领域的任务型对话系统中，以苹果 Siri 和微软 Cortana 为代表的语音助手已通过手机、操作系统等介质被人们广泛使用；另外，以亚马逊 Echo、谷歌 Home、百度小度、小爱同学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，为用户的日常生活提供了极大方便。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，例如中国的小冰、日本的 Rinna、印度的 Ruuh 等，使用用户也已达到了数千万。

在学术界，关于对话系统的早期研究主要针对于限定领域的具体任务，采用基于符号和规则的方法严格定义和限制输入的内容，并针对特定任务设计相应的规则、逻辑和语言模板。这种方法解释性和可维护性较好，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具有缺陷，也不适用于开放领域。近年来，随着互联网上社交数据的指数级增长、多类型语料库的完备和计算能力的极大提升，基于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，人机对话系统也由任务型服务的角色逐步转变为情感伴侣的角色。随着大数据和深度学习技术的发展，创建一个人机对话系统作为我们的私人助理或聊天伙伴将不再是幻想。

2 问题描述

本文的研究对象是开放领域的对话系统，以不同场景设置为标准，对话系统可分为单轮对话系统和多轮对话系统。单轮对话系统只针对于当前给出的语句，输出最佳的回复。多轮对话系统需要综合考虑历史对话信息，建立长期的对话依赖关系，给出更加符合整体对话逻辑的回复。以不同的构建方法为标准，可将开放领域对话系统的实现方法分为检索式、生成式和检索与生成相结合三大类：

(1) 检索式方法。检索式方法的主要思想是在多个候选回复中选择一个最佳的回答作为输出。它首先需要构建一个对话语料库，当用户输入话语后，系统从库中进行检索并选择一批候选回复，然后根据对话匹配模型对候选列表进行重排序并输出最佳回复。该方法的核心在于让匹配模型尽可能地克服查询和回复之间存在的语义差异。

(2) 生成式方法。由于深度学习在机器翻译和文本摘要等领域的成功应用，激发了人们对于神经生成对话系统的研究。生成式方法首先需要收集大规模对话语料作为训练数据，然后构建对话模型来学习输入语句与回复语句之间的对应关系。在预测阶段，系统将输入语句作为语义向量送入对话模型，对话模型逐个生成词语组成对应的回复话语。

(3) 检索与生成相结合的方法。由于检索式和生成式方法都存在各自对应的缺点，有一些研究工作将检索式和生成式相结合来构造开放领域对话系统，得到了非常不错的效果。

本文接下来将主要以开放领域的对话系统为研究对象，结合最近几年发表的文献对以上三类方法中所提出的经典模型进行概括、分析和比较，梳理其中的关键性问题及解决方案。

3 检索式方法

早期的检索式方法主要关注于单轮对话中的回复选择，Wang 等人^[1]提出了一种基于检索的对话生成模型，其方法核心是把上下文语句和候选回复分别编码为向量，然后利用这两个向量来计算两者之间的匹配分数：

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

其中 \mathbf{x} 表示输入语句的向量， \mathbf{y} 表示候选回复的向量， \mathbf{A} 是一个预先定义的矩阵。之后很多基于检索的对话系统都基于这个模型进行拓展和改进，深度学习的应用也使得此类模型的计算准确度得到了很大提高。Hu 等人^[2]提出利用深度卷积神经网络来学习输入与回复的表示，或是直接学习两个句子交互的表示，再利用多层感知机计算匹配分数，获得了较好的匹配效果。Tan 等人^[3]将循环神经网络和卷积神经网络混合应用在模型中，结合 CNN 捕捉 n-gram 内的本地交互和 LSTM 捕获长距离信息的优点，又加入了注意力机制在查询回复匹配任务上学习出了不错的效果。

由于单轮对话系统过于简单，不能很好地关联上下文之间的逻辑，之后的研究逐渐关注于多轮对话中的回复匹配问题。与单轮对话系统不同的是，多轮对话系统需要整合当前的查询语句和历史上下文信息作为输入，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，问题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。

3.1 以表示为中心的框架

以表示为中心的检索模型其核心思想是用模型将对话上下文信息先表征为语义向量，再计算其与回复的匹配分数。

Low 等人^[4]基于 Ubuntu Chat Logs 构建了一组大型非结构化的多轮对话系统语料，成为后续很多文章研究对话系统常用的数据集。与此同时提出基于 RNN 的基准模型（如图 1 所示）。该模型将历史上下文语句和查询语句同时拼接在一起作为输入，然后基于 TF-IDF 模型找出相似度最佳的候选回复，再用 RNN 或者 LSTM 模型将句子表征为向量计算匹配分数。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，从多方面改进了效果。

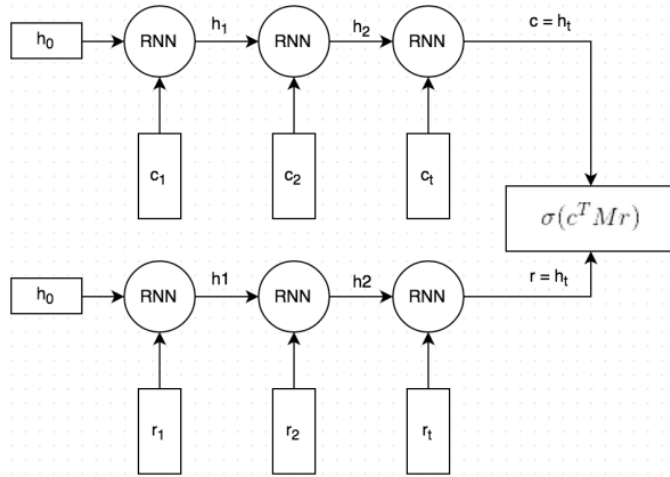


图 1 使用 RNN 同时对上下文和候选回复进行编码

Zhou 等人^[5]提出基于多视角的多轮对话检索模型。该模型将上下文信息作为输入，并基于 word 序列和 utterance 序列两个视角来计算匹配分数，最终结合两个匹配分数来选择最佳回复。其中，基于 word 序列的视角将文本中所有词按顺序输入到一个 GRU 中，将其隐藏向量表征为文本的语义表示；基于 utterance 序列的视角则基于 CNN，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 中输出文本的表示。模型从词语粒度和话语粒度级别分别计算对话上下文和候选回复的相关性然后进行融合，有效改善了排序效果，提升了回复质量。

3.2 以融合为中心的框架

以融合为中心的多轮检索模型是先将回复与对话上下文进行融合，再计算这两者之间的语义匹配特征。相比于以表示为中心的模型，该框架需要计算回复与每个上下文话语的融合信息，在更细的语义粒度上对上下文信息与回复的匹配分数进行计算。

基于卷积神经网络和循环神经网络。Wu 等人^[6]提出序列匹配网络框架实现了以语义融合为中心的多轮检索对话系统（如图 2 所示）。序列匹配网络的主要思想是：对每一个话语和候选回复先处理成词向量，然后计算一个 word 级别的相似度矩阵和一个 segment 级别的相似度矩阵，这两个矩阵经过 CNN 的卷积池化，得到一个个向量，这样就从上下文的多个粒度提取到了重要信息，然后将这些向量依次输入到 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 的隐藏层计算得出最后的匹配分数。

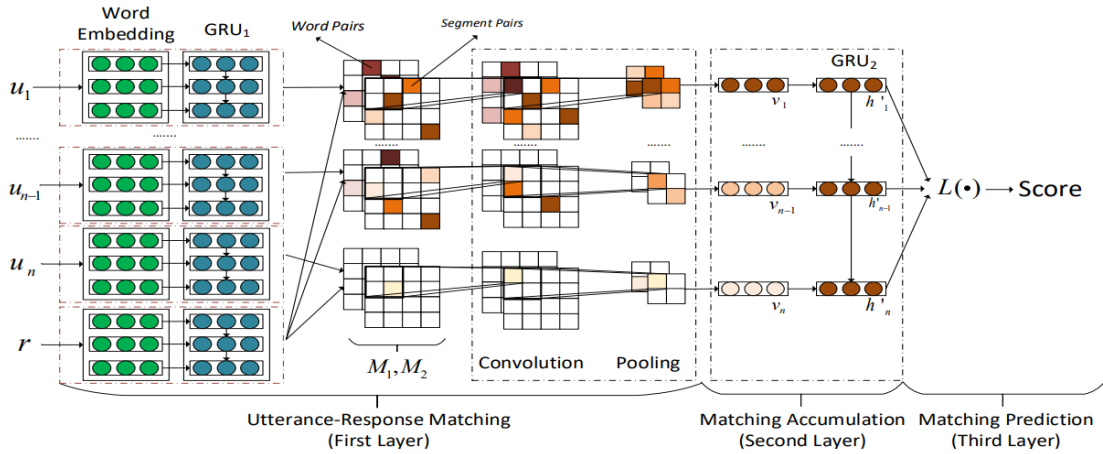


图 2 序列匹配模型框架

基于循环神经网络和注意力机制。Zhang 等人^[7]提出了一个深度对话整合模型 (DUA), DUA 从对话和回复中采用 attention 机制凸显关键信息, 忽略冗余信息, 最终获得话语和回复的匹配得分, 解决了以往多轮对话将历史会话直接拼接作为上下文信息所产生的噪声和冗余等问题。在语义表征过程中, 模型首先将查询分别与历史话语和回复拼接, 并采用 attention 机制和 GRU 得到每条话语的语义表示; 语义融合过程则是基于词粒度和句粒度两个级别的匹配矩阵, 通过卷积、最大池化和扁平化计算出每条话语与查询之间的匹配关系向量。最后, 将话语和查询的匹配关系向量输入到 GRU 中从而计算出最终的候选回复匹配分数, 计算最终匹配得分的时候充分考虑了各轮对话之间的关系。

3.3 检索式方法小结

对以上两种不同框架对比来看, 以表示为中心的检索对话模型, 在语义表征过程中话语与回复相对独立, 会丢失上下文中的一些特征。而以融合为中心的检索对话模型在匹配过程中能够提取到历史上下文中对回复有用的特征信息, 匹配效果更好, 但是算法结构更复杂、计算量更大。

4 生成式方法

基于检索的方法是一种基于“查询”的方法, 所生成的回复都是存在库中的质量较高的语句, 但在合适度上相对不足, 而且查询的成本和外部知识库规模的大小也成正比例关系。而随着深度学习方法的崛起, 高质量语料集的大量出现, 使得对基于生成式方法的对话系统研究逐渐流行起来。基于生成式方法的对话系统模型主要是利用已有的语料进行学习, 针对用户的输入产生合适的回复, 从而克服了检索式方法中外外部知识库规模所带来的成本限制。

4.1 序列到序列模型框架

序列到序列 (Sequence-to-Sequence, Seq2Seq) 模型, 又称编码器-解码器 (Encoder-Decoder) 模型, 是完全基于数据驱动的网络模型。作为一种非常流行的文本生成模型, Seq2Seq 模型在文本摘要、机器翻译等方面都有着较为成熟的应用。

Vinyals 等人^[8]最早将 Seq2Seq 模型运用在单轮对话生成系统上 (如图 3 所示)。该模型基于循环神经网络, 每次读取输入一个序列, 并预测输出一个序列。模型将对话历史上下文统一作为输入, 一次只读取一个词语。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结果作为当前时刻的输入，最后生成回复语句。该模型不需要特征工程和领域特殊性，结构上也较为简单，但却为许多文本生成问题提供了解决方案，并开启了利用深度学习方法构建生成式对话系统的研究。




图 3 经典的序列到序列模型框架

引入注意力机制。Shang 等人^[9]基于新浪微博构建语料库，并采用 Seq2Seq 模型框架实现单轮对话生成系统。模型首先用编码器对查询话语进行编码得到其语义向量表征，再用解码器对该语义向量解码得到回复序列。在编码和解码的过程中都使用 GRU 模型。文章提出了三种编码方案：第一种全局方案是利用全局编码器计算出全局语义向量，并将其送入解码器，这种方案能抓取到全局特征；第二种局部方案是用局部编码器基于注意力机制加权计算出局部语义向量，它依靠注意力模型选择不同位置的单词作为重要特征；第三种是结合全局编码和局部编码的方案（如图 4 所示），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，性能相比于前两个方案明显提高了许多。

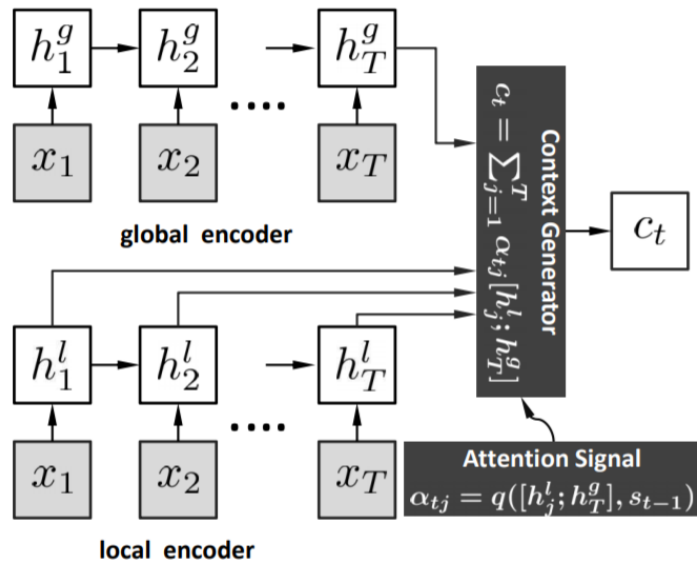


图 4 结合全局编码和局部编码的方案

4.2 层次序列到序列模型框架

基于 RNN 的 Seq2Seq 模型能在具有几十个词的句子中取得比较好的效果，但是对于多轮对话来说，对话上下文所记录的长度往往不止几十个单词，此时 Seq2Seq 模型就容易产生很多不相关的无意义回答，且对于多轮对话，Seq2Seq 模型缺乏对历史上下文的长期评估。为了解决这一问题，层次化模型思路被提出

以解决对话轮数过多和句子长度限制的问题。

Serban 等人^[10]基于层次化模型思路构建了对上下文句子序列建模的对话模型 HRED (Hierarchical Recurrent Encoder-Decoder)。该模型包含两部分编解码(1) Encoder RNN: 此部分在单词角度进行编解码, 基于 RNN 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, 主要用来抓取每个话语的表示语义;(2) Context RNN: 此部分在对话轮层面进行编解码, 基于 RNN 将多个话语的向量转换成对话上下文的向量表示, 并将历史对话和查询的信息集成在一起。最后将集成好的对话上下文表示输入到解码器 (Decoder RNN) 中解码。从效果上来说, 基于层次化的方法使得对话上下文之间的相关性有了较为明显的提高, 但是 HRED 模型相对于标准的 Seq2Seq 模型性能提高并不明显。

针对以上问题, Serban 等人^[11]认为 HRED 模型在生成回复词语时没有深入捕捉到隐藏在话语间的特征信息, 于是又提出了一种潜在变量分层递归编码器解码器模型(VHRED), 拓展了 HRED 的效果。该模型主要是在 Context RNN 中加入了一个高维的随机主题潜在变量增强了 HRED 模型, 在解码过程中先采样出潜在变量, 再生成回复序列。其中的潜在变量可以是某种情感或某个话题, 通过识别潜在变量能针对回复进行初步的分类。这使得模型能够在生成过程中对层次结构化序列进行建模, 同时可以保持长期上下文信息, 因此提高了回复的多样性。

4.3 基于强化学习的模型框架

基于 Seq2Seq 的模型在多项文本生成任务上均取得了不错的效果, 但很多情况下, 这类模型的训练通常需要庞大的数据集作为支撑, 而且在对话过程中每轮对话的质量都会对后续的对话产生影响。

于是带有奖励反馈机制的强化学习被应用到对话系统中。Li 等人^[12]提出了利用强化学习进行对话策略学习的方法, 使用如图 5 所示的结构模拟两个代理之间的对话过程, 该方法使用 Seq2Seq 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: 连续对话轮次之间的语义相似性;(2) 信息流: 同一个人的话, 应该在语义上避免重复;

(3) 轻松回答: 话语能很容易地给出合适的回复。利用强化学习能解决 Seq2Seq 模型短视的问题, 提升回复的多样性, 同时可以减少训练过程中对训练语料集的庞大需求。

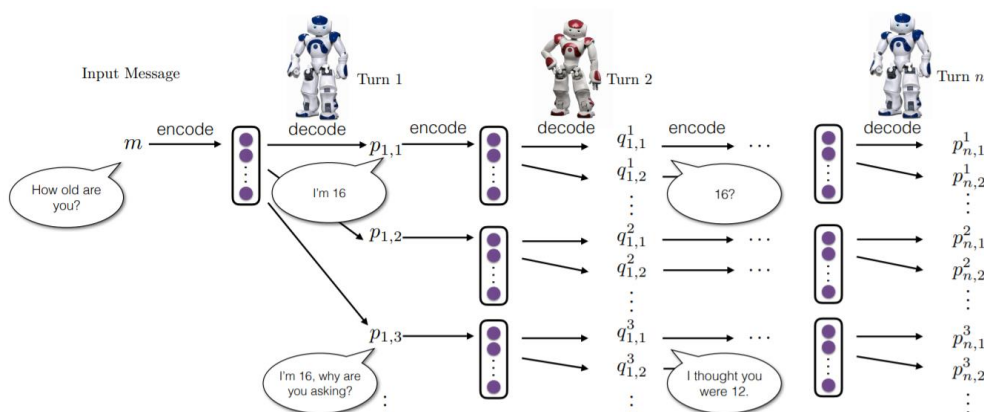


图 5 基于强化学习的模型框架

Zhang 等人^[13]发现在多轮人机对话的过程中, 用户的隐性反馈例如立场、情绪和谈话状态等反应对人机对话的生成具有一定影响。于是基于强化学习框架,

提出新的奖励函数来整合会话过程中生成的隐性反馈，优化会话生成的长期目标。他们将 **Stance**、**Sentiment** 和 **Stalemate** 三种隐性反馈作为奖励加入到对话生成过程中，并用 Seq2Seq 模型初始化会话策略，设计两个对话机器人来探索学习的动作状态空间，使用随机梯度下降方法来更新 Seq2Seq 模型的参数，以最大化奖励的期望。实验结果表明，该方法在自动评价和人工评价方面均优于单纯的 Seq2Seq 模型和当时最新的强化学习模型。

4.4 生成式方法小结

近期的对话生成模型大多基于层次化 Seq2Seq 模型框架实现，并通过对该框架进行改进来优化对话上下文的向量表示。改进的层次化框架模型对话语的层级关系直接进行建模，能生成更丰富、更有意义的回复，效果更好。基于强化学习框架的对话生成系统在 Seq2Seq 模型的基础上引入反馈机制，能够进一步改进模型效果并减少对庞大数据集的依赖。

5 检索与生成相结合

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。但是检索方法的前提是对话语料库中存在能作为回复的话语，大规模语料库是检索式系统成功的关键。近年来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的质量不可控，甚至可能出现语句不通顺、句法错误等问题。因此关于对话系统的最新研究都尝试将检索和生成两者集成起来，结合两种方法的优点来建立开放领域的对话系统。

Song 等人^[14]将检索模型得到的候选回复和原始查询语句同时作为 Seq2Seq 模型中的编码输入从而生成结果，然后再将该结果加入到原检索候选集中，再进行重排序。该模型巧妙地将检索和生成相结合，使得对于一个输入话语，模型能够从不同的渠道和角度输出优化的结果，从而提升了回复质量。

Wu 等人^[15]将检索和生成相结合提出了一个全新的方法：把“先检索，后改写”的思想用于回复生成。该方法首先从预定义的语料中检索到原回复，然后根据该回复原本的上下文和当前上下文之间的差异来改写此回复，从而使得到的回复既保证了语法和信息，也获得了上下文的语义连贯性。这种新的范式不仅继承了检索式方法回复流畅和富有信息的优势，而且还享有生成式方法的灵活性和相关性。实验表明，这一方法在多样性、相关性和原创性方面均优于传统模型。

Zhu 等人^[16]提出了一种检索增强的对抗式回复生成模型（如图 6 所示），该方法基于编码器-解码器框架和对抗学习，并利用检索式模型得到 N-best 候选回复来构造判别器。模型主要由三部分组成：（1）检索模块：给定用户的输入消息，该模块在训练集中经由检索、重排序，得到 N-best 候选回复。（2）生成器：生成器是一个 Seq2Seq 模型，它接收输入消息和上一步产生的 N-best 候选回复作为输入，然后生成相应的回复。（3）判别器：本质上是一个二元分类器，用于判断一个回复是人生成的还是机器生成的。在判别过程中首先引入 N-best 候选回复作为参考，计算得到一个回复表示，然后将该回复表示结合输入消息表示作为判别器的输入，经由多层感知机预测出回复是人生成的概率。最后在对抗训练下，判别器和生成器相互博弈优化，从而不断提高生成回复的质量。实验表明，在基于人工评价的合适度、多样度和流畅度三个方面，该方法都取得了不错的效果。

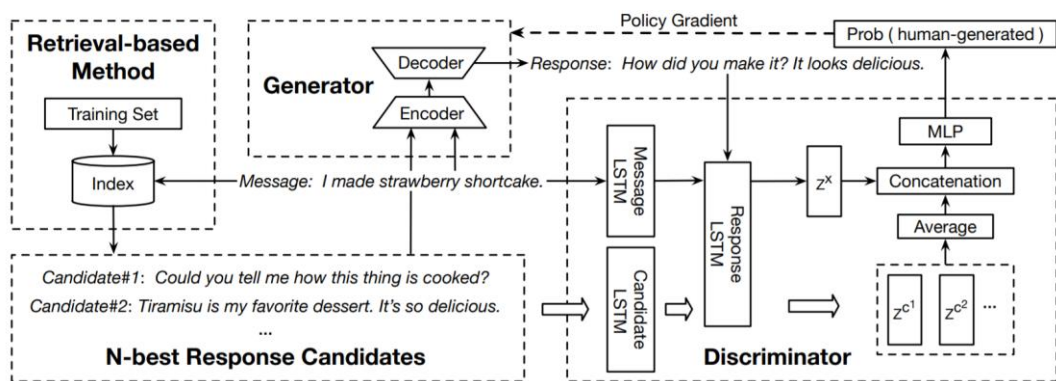


图 6 检索增强的对抗式回复生成模型

检索与生成相结合方法小结: 将检索和生成方法结合起来能对开放域对话系统的性能起到显著的提升作用。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。生成式方法则能够对更复杂的语境建模, 例如情感、个性化等也逐渐成为近年来对话系统的研究热点。如何更好地结合这两者的优势, 克服相应的缺点, 建立更加智能化的对话系统, 仍是一个非常值得深入研究的方向。

6 总结与展望

本文主要以开放领域的对话系统为研究对象, 从构建方法的角度论述了对话系统检索式、生成式和检索与生成相结合三种不同方法的演变过程, 重点梳理了各类方法中的关键问题及经典模型。通过对国内外现有研究进行梳理, 发现开放领域对话系统作为人工智能研究的一个分支, 受到了越来越多的关注及重视。由于自然语言的丰富性及复杂性, 特别是处于大数据高速发展的今天, 如何提升对话系统的性能仍是研究人员面临的重要问题。

由于研究时间较短, 在开放领域对话系统中检索式方法和生成式方法都还不能真正达到与人类流畅交流的效果, 许多关键性问题还需要进行深入研究, 以下对开放领域对话系统的研究趋势进行展望:

融入情感: 基于数据驱动的对话系统着重于建立输入话语和输出回复之间对应的语义关系。而现实中, 人类之间的真实对话还会受到情感等方面的影响, 可以将情感分析领域取得的成果, 引入对话系统来识别用户对话时的情绪, 并根据不同的情感类型给出相应的回复, 还可以基于强化学习建立带有情感反馈机制的交互式对话模型。

个性化回复: 每个人都有自己说话时的方式和偏好, 对语言的理解能力也会因年龄、学历和阅历等因素的影响而不尽相同。智能的对话系统应该主动结合用户的偏好, 给出符合他们个性的回复。当前, 大多数训练语料数据集都包含不同人的对话内容, 通用模型不能解决个性化回复问题, 可以尝试通过用户建模的生成式方法对个性化的对话模型进行探索。

回复逻辑: 对话中的逻辑问题是目前对话系统的关键难点之一。人类在对话过程中经常包含常识的演绎和推理, 而基于数据驱动的开放领域对话系统一般都是以语料库为基础, 给出概率最大的最佳回复, 无法保证回复的逻辑与上下文一致。可以尝试结合常识推理领域, 将上下文的对话逻辑进行建模并整合到回复生成中, 从而加强对话之间的回复逻辑。

参考文献

- [1] 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.
- [2] 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.
- [3] Tan M, Dos Santos C, Xiang B, et al. Improved representation learning for question answer matching[C]//Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). 2016: 464-473.
- [4] 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.
- [5] Zhou X, Dong D, Wu H, et al. Multi-view response selection for human-computer conversation[C]//Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. 2016: 372-381.
- [6] Wu Y, Wu W, Xing C, et al. Sequential Matching Network: A New Architecture for Multi-turn Response Selection in Retrieval-Based Chatbots[C]//Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). 2017: 496-505.
- [7] Zhang Z, Li J, Zhu P, et al. Modeling Multi-turn Conversation with Deep Utterance Aggregation[C]//Proceedings of the 27th International Conference on Computational Linguistics. 2018: 3740-3752.
- [8] Vinyals O, Le Q. A neural conversational model[J]. arXiv preprint arXiv:1506.05869, 2015.
- [9] Shang L, Lu Z, Li H. Neural Responding Machine for Short-Text Conversation[C]//Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (Volume 1: Long Papers). 2015: 1577-1586.
- [10] Serban I V, Sordoni A, Bengio Y, et al. Building end-to-end dialogue systems using generative hierarchical neural network models[C]//Thirtieth AAAI Conference on Artificial Intelligence. 2016.
- [11] 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.
- [12] Li J, Monroe W, Ritter A, et al. Deep reinforcement learning for dialogue generation[J]. arXiv preprint arXiv:1606.01541, 2016.
- [13] Zhang W N, Li L, Cao D, et al. Exploring implicit feedback for open domain conversation generation[C]//Thirty-Second AAAI Conference on Artificial Intelligence. 2018.
- [14] Song Y, Yan R, Li X, et al. Two are better than one: An ensemble of retrieval-and generation-based dialog systems[J]. arXiv preprint arXiv:1610.07149, 2016.
- [15] Wu Y, Wei F, Huang S, et al. Response generation by context-aware prototype editing[C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2019, 33: 7281-7288.
- [16] Zhu Q, Cui L, Zhang W, et al. Retrieval-Enhanced Adversarial Training for Neural Response Generation[C]//Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. 2019: 3763-3773.