

Q2SM:基于 BERT 的多领域任务型对话系统状态跟踪算法*

张家培¹ 李舟军^{1,**}

(1. 北京航空航天大学 计算机学院, 北京市 100191)

摘要: 基于管道的方法是当前任务型对话系统的主要构建方式, 在工业界具有广泛的应用, 而对话状态跟踪 (Dialogue State Tracking, DST) 是任务型对话系统中的核心任务。面对传统的方法在多领域场景下表现较差的问题, 该文结合语言模型预训练的最新研究成果, 提出了一种基于 BERT 的对话状态跟踪算法 Q2SM (Query to State Model)。该模型的上游使用了基于 BERT 的句子表征与相似度交互的槽判定模块, 下游使用了一种面向对话状态跟踪任务的自定义 RNN: DST-RNN。在 WOZ2.0 和 MultiWOZ2.0 两个数据集上的实验表明, Q2SM 相比于之前的最好模型, 分别在联合准确率和状态 F1 值两个评价指标上提升了 1.09% 和 2.38%; 此外, 模型消融实验验证了 DST-RNN 相比于传统的 RNN 或 LSTM, 不仅可以提升评价指标值, 还可以加快模型的收敛速度。

关键词: 任务型对话系统; 对话状态跟踪; 多领域; BERT

中图分类号: TP391

文件标识码: A

Q2SM: Dialogue State Tracking Model Based on BERT for Multi-Domain Task-Oriented Dialogue System

Jiapei Zhang¹ Zhoujun Li^{1,**}

(1. School of Computer Science and Engineering, Beihang University, Beijing 100191, China)

Abstract: The pipeline method is the main way to build a task-oriented dialogue system, which is widespread in industrial circle. Dialogue State Tracking (DST) is the core task in task-oriented dialogue system. Facing the difficulty of multi-domain, this paper introduces a novel model named Q2SM (Query to State Model) based on BERT. The upstream of Q2SM is a model based on sentence representation with BERT and similarity interaction, while the downstream is a new type of RNN named DST-RNN. Experiments in WOZ2.0 and MultiWOZ2.0 datasets show that the model outperforms the existing state-of-the-art model by 1.09% in joint-accuracy and 2.38% in F1 score; moreover, the model ablation study show that the DST-RNN could speed up model convergence besides improve the evaluation index.

Keywords: Task-Oriented Dialogue System; Dialogue State Tracking; Multi-Domain; BERT

0 引言

对话系统是当前自然语言处理领域的研究热点之一。任务导向型对话系统 (Task-Oriented Dialogue System, 以下简称任务型对话系统) 是对话系统领域里的重要研究方向, 在真实的工业界具有非常广泛的应用场景, 如苹果 Siri、小度助手等智能服务, 京东 Jimi、阿里小蜜等导购机器人。任务型对话系统在研究领域通常有两种构建方法, 一种是基于管道的 (pipeline), 这种

方法将对话系统分为自然语言理解 (Natural Language Understanding, NLU)、对话管理 (Dialogue Management, DM)、自然语言生成 (Natural Language Generation, NLG) 三个级联模块^[1], 用户的文本输入依次经过三个模块处理, 最终生成文本回复, 这种方法也是工业界的主流处理方法; 另一种是端到端的 (end-to-end), 即直接根据用户输入产生输出, 这种方法目前仍停留在研究阶段^[2]。

对话状态跟踪 (Dialogue State Tracking, DST) 是基于管道的任务型对话系统里的重

* 收稿日期: 2019-6-18; 定稿日期: 2019-8-15

基金项目: 国家自然科学基金 (61672081、U1636211、61370126、61602025); 国家重点研发计划 (2016QY04W0802)

** 本文通讯作者: 1963 年生, 博士, 教授, 博士生导师。CCF 高级会员, 主要研究领域为数据挖掘与自然语言处理、网络与信息安全。Email: lizj@buaa.edu.cn。

要任务，其主要目标是在人机对话过程中维持对话的上下文信息，并以预定义好的状态的形式展示出来。图 1 展示了一个典型任务型对话场景和对应的状态变化过程。



图 1 典型对话场景与状态变化过程实例

对话状态跟踪任务通常有两种做法，一种是先对用户语句进行自然语言理解（NLU），识别用户输入的关键信息（一般是意图和槽），再根据规则或模型进行状态跟踪；另一种则是局部端到端的，直接根据用户的输入和历史状态，得到当前的状态，这种方法可以减少级联模块中的中间损失。

虽然基于管道的构建方法在工业界已经得到广泛应用，但该方法仍然面临着严峻的数据匮乏的问题和领域间迁移困难的问题^[2]。一方面，领域知识是限定领域的对话系统所必须的；另一方面，如果对一个全新领域构建对话系统，则需要重新构造知识，训练模型。因此，如何合理利用对话数据，同时能够在多领域场景中共享信息，提升识别准确率，是任务型对话系统的重要研究方向。

近两年来，预训练（Pre-Train）方法在 NLP 任务中展示了强大的能力，当前在绝大部分 NLP 经典任务中，最佳方法（State-of-the-Art）都是以预训练模型为基础的。在这些预训练模型中，BERT^[3]是迄今应用范围最广、效果最佳的预训练模型。使用预训练模型处理任务型对话系统中的子任务，有助于缓解数据缺失的问题。

本文在面向多领域的情景下，以管道式的任务型对话系统中的对话状态跟踪任务为研究对象，采用基于 BERT 预训练模型的方法，对管道式任务对话系统中的关键组件和模块进行重新设计，提出了基于 BERT 的面向多领域的对话状态跟踪模型 Q2SM-BERT（Query to State Model Based on

BERT）：该模型以 BERT 预训练模型为基础，利用了槽与句子编码向量的交互关系，直接从当前轮的用户输入和历史状态预测当前轮的实际状态。实验表明，该模型可以在 WOZ2.0 和 MultiWOZ2.0 两个数据集上取得了更优的结果；此外，模型消融实验显示，本文提出的面向对话状态跟踪的 DST-RNN，相比于经典的 RNN，能够使模型更快收敛。

本文的主要内容如下：第一节介绍对话状态跟踪任务的相关研究和预训练模型的当前工作；第二节介绍基于 BERT 的 Q2SM 模型的模型细节和构建方法；第三节介绍模型相关的实验设计及实验结果；最后一节对本文的工作进行了总结。

1 相关工作

本文的研究涉及基于管道的任务型对话系统中的对话状态跟踪任务以及基于语言模型的预训练两个方向，因此下面分别介绍这两个研究方向的相关工作和当前进展。

1.1 基于管道的任务型对话系统中的对话状态跟踪任务

基于管道的多模块级联方法的设计雏形来自于 Steve Young^[1]发表于 2000 年的论文，通常包括语音识别（ASR）、自然语言理解（NLU）、对话管理（DM）、自然语言生成（NLG）、语音合成（TTS）五个模块。因为对话状态跟踪（DST）任务既可以是对话管理模块的一个子任务，也可以是结合自然语言理解和对话管理的部分的端到端模型，所以自然语言理解和对话管理是与对话状态跟踪任务联系最紧密的两个模块。下面简要回顾一下这两个模块上的研究工作和面向多领域的对话状态跟踪任务中的主流算法。

早期的自然语言理解主要使用人工设计的模板与规则^[4,5]，这种方法需要大量的领域知识和人工标注，无法应对复杂的场景。后续的研究主要分为两个方向，一个是研究更复杂的语义解析技术；另一个则是数据驱动的基于统计的方法，如经典的机器学习算法条件随机场^[6]、支持向量机^[7]等，都被应用于自然语言理解中的分类和序列标注任务中来。此外，深度学习模型也在自然语言

处理任务中取得较好的效果,如 Hashenmi^[8]使用 CNN 做句子向量表示, Peters^[9]使用 Bi-LSTM 和 CRF 做槽识别任务,均取得了较好效果。

传统的对话管理模块同样多使用基于规则的方法,如 Harald 等人^[10]设计一个有限状态自动机来指导模型进行状态跟踪, David 等人^[11]设计了基于表格的(form-based)的对话管理模型,通过可选的和强制的两种槽位种类来控制状态。然而随着一批公开数据集的发布,如 DSTC^[12], DSTC2^[13]等,一大批数据驱动的基于深度学习的对话状态跟踪算法被先后提出并成为主流研究方向。工作^[14]首先使用朴素的深度神经网络(DNN),通过最大化在训练数据上的似然概率来优化参数模型;接着 Henderson^[15]等人使用双向循环神经网络(RNN)来处理状态跟踪问题,并通过一些无监督数据来增强效果。

传统的对话状态跟踪模型通常要先得到自然语言理解模块的输出,再结合历史状态更新自己的状态,因此往往无法进行领域间的信息共享和扩展。结合自然语言的表示学习的最新进展, Mrkšić 等人^[16]提出了不使用自然语言理解模块和预定义词典,而直接从自然语言和词嵌入表示中对对话状态进行预测的思路,该工作提出的神经信念跟踪模型(NBT)在两个经典数据集上均达到或超过了传统的方法。这为端到端的对话状态跟踪任务的研究思路开辟了新的方向。之后 Ramadan 等人^[17]提出的 MDBT 模型,计算了用户输入语句与领域实体间的语义相似度,并以此为重要特征来计算对话状态的概率分布,目前该方法在端到端对话状态跟踪任务上取得了最佳结果。

1.2 基于语言模型的预训练与 BERT

近两年来,基于语言模型的预训练方法在自然语言处理领域取得了巨大成功,推动了许多自然语言处理领域经典任务的研究进展。

Dai 和 Le^[18]最早提出了通过微调预训练语言模型进行后续任务,该工作提出了预测序列下一个词和将序列编码为向量再通过向量解码两种无监督训练方法。在训练得

到一个预训练模型后,通常有两种方法将模型应用到下游任务中。一种是基于特征的(feature-based),一种是基于微调的(fine-tuning)。

基于特征的典型应用是 ELMo^[19],该模型首先在双向语言模型上进行预训练。得到预训练模型后,输入一个句子,即可得到句子中的每个词的词嵌入表示,然后在目标任务中将词嵌入表示作为额外特征拼接到传统特征里,这种额外的特征可以有效提升模型效果。

基于微调的典型应用是基于转换器^[20](Transformer)的双向编码表示模型 BERT^[3],该模型则的预训练是同时进行掩码语言模型和后句预测两个子任务,优化目标函数是这两个任务评测指标的结合。预训练完成后,只需根据特定任务在与训练模型后加一个额外的输出层,即可进行微调训练。基于 BERT 的模型在一大批自然语言处理基础任务中得到最佳结果^[3]。

2 模型设计

2.1 对话状态跟踪任务形式化描述

首先将对话状态跟踪任务进行形式化描述如下:用户在时刻 t 的输入语句(query)为 q_t ,系统回复为 r_t ,则整轮对话可以表示

为 $Q = \{q_1, r_1, \dots, q_t, r_t, \dots, q_T, r_T\}$,其中 T 为

对话轮次;目标则为获得用户在任意 t 时刻的对话状态 $\vec{s}_t = (v_t^1, v_t^2, \dots, v_t^N)$,其中

$v_t^i \in V^i$, V^i 为第 i 个槽预定义好的状态集,

N 是多个领域中槽的总数量。

在对话从时刻1进行到时刻 T 时,模型会预测出 T 个状态 $\vec{s}_1, \vec{s}_2, \dots, \vec{s}_T$,这 T 个状态与真实状态越接近,则该对话状态跟踪任务则完成得越好。常用的衡量指标包括联合准确率和 F-score。

2.2 基于BERT的用户输入与对话状态的端到端模型 Q2SM-BERT

将该模型命名为 Q2SM (Query to State Model) 的原因在于, 该模型利用 BERT 预训练模型里的丰富信息, 直接从用户输入 query 中学习特征, 通过和槽嵌入矩阵进行交互, 直接预测对话状态。该模型的核心思想主要有两个方面:

1) 利用 BERT 的编码能力, 对输入句子进行句子层级的特征表示; 使用槽嵌入将每个槽的语义用特征向量表示; 然后将句子特征表示与槽特征表示进行相似度交互, 得到该句子在这些槽中的表示向量;

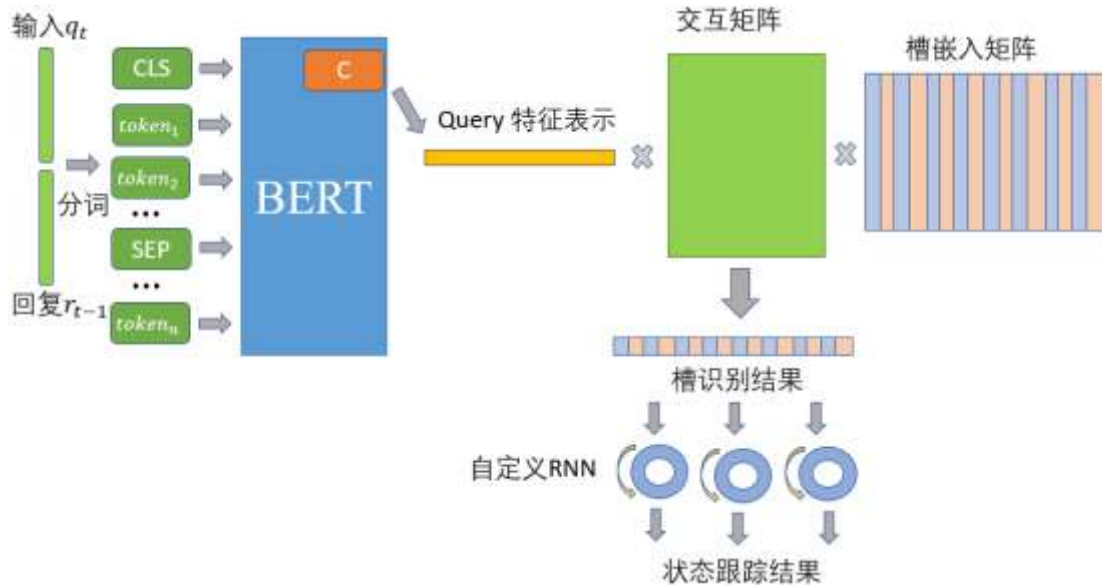


图 2 Q2SM 模型结构简图

2) 使用自定义的 RNN 对槽识别结果进行时间序列建模, 得到每个时间步下每个槽的状态分布, 进而可以获得每个槽的状态;

模型的基本结构如图 2 所示, 其中的两个子模块的细节则分别在 2.3 节和 2.4 节中介绍。

2.3 基于BERT的句子表征与基于相似度交互的槽判定模块

BERT 的基本结构是多层双向 Transformer 结构的叠加, 其细节可以参考论文^[3]。BERT 输入序列中的第一个元素 (即 CLS 标识符) 对应的输出可以作为句子级别

的特征表示。设用户当前轮的输入为 q_t , 上

轮系统回复为 r_{t-1} , 则按 BERT 要求将输入

拼接为 $[\text{CLS}, q_t, \text{SEP}, r_{t-1}]$, 经过分词得到

token 序列 $\{t_1, t_2, \dots, t_t\}$, 依次输入到 BERT

模型中, 取 CLS 标签的输出作为句子的特征表示, 设为 \vec{c} , 该特征向量的维度为 BERT 的隐层元的个数, 设为 H 。

另一方面对于槽的信息表示, 设共有 K

个槽, 第 i 个槽的特征表示为 \vec{v}_i , 则这 K 个槽的特征可以表示为一个矩阵 $V_{D \times K} = (\vec{v}_1, \vec{v}_2, \dots, \vec{v}_K)$, 其中 D 为槽特征向量的维度。

对于交互矩阵 M , 其矩阵大小为 $H \times D$, H 为 query 特征向量的维度, 也是 BERT 的隐层单元数, D 为槽特征向量的维度; 经过交互矩阵乘, 可以得到槽识别结果向量 \vec{s} , 该向量维度为 K , 其中每个元代表在一个槽上的预测结果。

基本的数学公式表示如下:

$$t_1, t_2, \dots, t_n = \text{Segment}(q) \quad (1)$$

$$\vec{c} = \text{BERT}(t_1, t_2, \dots, t_n) \quad (2)$$

$$V_{D \times K} = (\vec{v}_1, \vec{v}_2, \dots, \vec{v}_K) \quad (3)$$

$$\vec{s} = \vec{c}^T M V \quad (4)$$

最后得到的槽识别结果向量 \vec{s} ，按照状态集的定义被分割对应各个槽的状态集大小的的向量，即：

$$\vec{s}_t = \vec{x}_1 \parallel \vec{x}_2 \parallel \dots \parallel \vec{x}_N \quad (5)$$

其中 \parallel 为连接操作， N 为多领域里槽的数量； \vec{x}_n 是后续自定义状态跟踪 RNN 的输入，其长度即第 n 个槽的状态数的数量。

2.4 面向对话状态跟踪的自定义 RNN： DST-RNN

循环神经网络 RNN 常用于序列模型构建，普遍应用在时间序列建模、NLP 语言模型等场景中。对于一个典型的 RNN，设当前时间步为 t ，模型输入为 x_t ，历史状态为 h_{t-1} ，可训练参数为 W ，则当前状态 h_t 遵循：

$$h_t = f(x_t, h_{t-1}, W) \quad (6)$$

其中，不同的映射规则 f 对应不同的 RNN，也相应在不同的场景中发挥不同的作用。

在对话状态跟踪这个特定场景中，我们使用一个自定义的 RNN 模型，在时间维度上建模用户状态，研究槽识别结果与历史状态如何影响当前时间步的状态。设当前的时间步为 t ，则有输入 \vec{x}_t 和历史状态 \vec{h}_{t-1} ；取输入 x_t 的最后一个元 $e = \vec{x}_t^{(-1)}$ ，并将其扩展为向量，则有 $\vec{e} = (e, e, \dots, e)^T$ ，使用如下的状态更新公式：

$$\vec{h}_t = \vec{x}_t \square (\vec{1} - \vec{e}) + \vec{h}_{t-1} \square \vec{e} + \vec{b} \quad (7)$$

预测结果 y_t 是当前时间步 t 在状态空间上的概率分布，满足：

$$y_t = \text{softmax}(h_t) \quad (8)$$

此外，我们预设置初始状态 \vec{h}_0 设置如下：

$$\vec{h}_0 = (0, \dots, 0, 1) \quad (9)$$

3 实验

3.1 数据集

本文实验建立在数据集 WOZ2.0^[17]和 MultiWOZ2.0^[21]上。WOZ2.0 是面向餐馆预定场景的单领域数据集，在 WOZ1.0^[16]版本的 600 轮对话基础上扩展到 1200 轮。该数据集可以有效检验模型在单领域上的建模效果；而 MultiWOZ2.0 数据集是目前领域内最大的面向多领域的任务型对话数据，共有超过 8000 轮对话，且平均每轮对话的轮数为 13.68。

为了与之前的模型 NBT^[16]和 MDBT^[17]进行客观公平的对比，我们并没有使用 MultiWOZ2.0 数据集中的全部领域（domain）和槽（slot），而如工作^[17]中一样，选择了数据较多的 7 个领域中的 5 个（attraction、hotel、restaurant、taxi、train）和 30 个槽中的 27 个，共 663 个槽值，经过上述筛选，共得到 5921 轮对话作为训练数据。

3.2 评测指标

本实验主要通过联合准确率和状态 F1-score 两个角度来对模型效果进行评价。

设 N 为对话的总数， T_n 为第 n 组对话的轮数， S 为预定义好的对话状态总数， $\hat{y}_{n,t}^{(s)}$ 为模型在第 n 组对话的第 t 轮中对第 s 个状态的预测值， $y_{n,t}^{(s)}$ 则为对应的正确值。

联合准确率（joint-accuracy）以轮为单位，每轮对话中所有状态均正确才认为状态识别是准确的，联合准确率衡量正确轮次占所有轮次的比例，公式如下：

$$joint = \frac{\sum_n^N \sum_t^T \mathbf{I}[\forall s, \hat{y}_{n,t}^{(s)} = y_{n,t}^{(s)}]}{\sum_n^N T_n} \quad (10)$$

F1 值是针对所有槽的，因为每个槽都有一个默认的无意义值，因此将之视为负例，而其他所有有实际意义的值视为正例，则 F1 值可以衡量槽个体识别准确程度。首先定义：

$$TP = \sum_n^N \sum_t^T \sum_s^S \mathbf{I}[\hat{y}_{n,t}^{(s)} = y_{n,t}^{(s)} = 1] \quad (11)$$

$$TN = \sum_n^N \sum_t^T \sum_s^S \mathbf{I}[\hat{y}_{n,t}^{(s)} = y_{n,t}^{(s)} = 0] \quad (12)$$

$$FP = \sum_n^N \sum_t^T \sum_s^S \mathbf{I}[\hat{y}_{n,t}^{(s)} = 1, y_{n,t}^{(s)} = 0] \quad (13)$$

$$FN = \sum_n^N \sum_t^T \sum_s^S \mathbf{I}[\hat{y}_{n,t}^{(s)} = 0, y_{n,t}^{(s)} = 1] \quad (14)$$

F_1 值则定义为：

$$P = \frac{TP}{TP + FP}, R = \frac{TP}{TP + FN} \quad (15)$$

$$F_1 = \frac{2PR}{P + R} \quad (16)$$

3.3 超参配置

本次实验使用 BERT-Base 版本，学习率设为 $5e-5$ ，学习率热身系数为 0.1（前 10% 的训练，学习率从 0 线性递增至设定值，之后再线性递减，在所有 epoch 训练完毕时降至 0），槽嵌入的维度为 384，epoch 数为 10，批次大小为 4，使用均值为 0、方差为 0.1 的高斯分布初始化参数，其余超参使用 BERT-Base 模型自带的默认值。

3.4 单领域数据集实验结果

WOZ2.0 数据集是面向餐馆预定的单领域数据集，可以衡量模型在单领域中对数据进行建模和拟合的能力。在该数据集上各模型的主要表现如表 1 所示：

表 1 WOZ2.0 数据集各模型联合准确率表现

| 模型 | 联合准确率 |
|----------------------|--------------|
| NBT ^[16] | 84.2% |
| MDBT ^[17] | 85.5% |
| Q2SM | 87.3% |

从表 1 中可以看出，在餐馆预定这个领域中，本文提出的 Q2SM 模型在联合准确率这个指标上相比于之前的基线模型 NBT 和之前的最佳模型 MDBT 有较大的提升。提升的主要因素在于 BERT 模型的加入，引入了外部数据，得到更有效的特征表示。

3.5 多领域数据集实验结果

MultiWOZ2.0 数据集是跨 5 个领域的多领域数据集，该数据集上的结果反映了模型的面向多领域时的对话状态跟踪能力。训练结果列于表 2。

表 2 MultiWOZ2.0 数据集各模型联合准确率

| 及 F1 值表现 | | |
|----------------------|---------------|---------------|
| 模型 | 联合准确率 | F1 值 |
| NBT ^[16] | - | - |
| MDBT ^[17] | 0.6815 | 0.8501 |
| Q2SM | 0.6924 | 0.8729 |

从表 2 中可以看出，Q2SM 模型在多领域数据集上依然普遍超出之前的 State-of-the-Art 模型 MDBT，而 NBT 模型则不支持多领域下的状态跟踪。Q2SM 模型的优势原因可能主要包括两个方面：1) BERT 预训练模型的初始参数中包含许多文本信息，能够有效对用户的输入 query 进行编码表示；2) 自定义的 RNN 模型，使用更精巧的状态更新规则，能够更有效地降低误差，提升精度。但自定义的 DST-RNN 单元的有效性需要进一步的消融实验（Ablation Study）

3.6 DST-RNN 消融实验

为了验证面向对话状态跟踪的 DST-RNN 单元的有效性，设计如下消融实验：新模型的前半部分使用 2.3 节所述的基于 BERT 的句子表征与基于相似度角度的槽判定模块，而后半部分分别用传统 RNN 和 LSTM 进行对话状态跟踪。在记录联合准确率和状态 F1 值这两个指标的同时，还记录了模型的收敛速度，收敛速度定义为模型验

证集上 F1 值达到最优解 50%时，模型训练量占总量的比例。

表 3 针对自定义 RNN 的消融实验结果

| RNN 单元 | 联合准确率 | F1 值 | 收敛速度 |
|---------|---------------|---------------|--------------|
| BaseRNN | - | - | 不收敛 |
| LSTM | 0.6911 | 0.8702 | 28.79% |
| DST-RNN | 0.6924 | 0.8729 | 9.46% |

表 3 展示了不同的 RNN 单元的不同结果，首先从联合准确率和 F1 值的角度，面向对话状态跟踪的自定义 RNN 相比于 LSTM 在联合准确率和 F1 值都有一定的提升。此外，DST-RNN 在模型收敛速度方面优势较明显；而最基本的 BaseRNN，因为梯度消失的问题，收敛速度极慢，在有限调节超参的情况下几乎不起收敛。

4 总结

本文提出了一种基于 BERT 的对话状态跟踪模型 Q2SM，旨在解决面向多领域的任务型对话系统中的状态跟踪任务。Q2SM 模型的上游是基于 BERT 的句子表征和相似度交互的槽判定模块，下游则为本文新提出的用于对话状态跟踪的自定义 RNN：DST-RNN。

在 WOZ2.0 和 MultiWOZ2.0 两个数据集上的实验显示，Q2SM 模型在联合准确率和状态 F1 值两个关键指标上都超过了原有的最佳模型 MBDT；此外，消融实验还验证了 DST-RNN 相比于传统 RNN 或 LSTM 单元，不仅在评测指标上占优，而且具有更快的收敛速度。

参考文献

- [1] Young S J. Probabilistic methods in spoken-dialogue systems[J]. Philosophical Transactions of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences, 2000, 358(1769): 1389-1402.
- [2] Chen H, Liu X, Yin D, et al. A survey on dialogue systems: Recent advances and new frontiers[J]. ACM SIGKDD Explorations Newsletter, 2017, 19(2): 25-35.
- [3] Devlin J, Chang M W, Lee K, et al. Bert: Pre-training of deep bidirectional transformers for language understanding[J]. arXiv preprint arXiv:1810.04805, 2018.
- [4] 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
- [5] Dahl D A, Bates M, Brown M, et al. Expanding the scope of the ATIS task: The ATIS-3 corpus[A]. Proceedings of the workshop on Human Language Technology[C]. Association for Computational Linguistics, 1994, 43-48.
- [6] Wang Y Y, Acero A. Discriminative models for spoken language understanding[C]//Ninth International Conference on Spoken Language Processing. 2006.
- [7] Pradhan S S, Ward W H, Hacioglu K, et al. Shallow semantic parsing using support vector machines[C]//Proceedings of the Human Language Technology Conference of the North American Chapter of the Association for Computational Linguistics: HLT-NAACL 2004. 2004.
- [8] 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.
- [9] Peters M E, Ammar W, Bhagavatula C, et al. Semi-supervised sequence tagging with bidirectional language models[J]. arXiv preprint arXiv:1705.00108, 2017.
- [10] Aust H, Oerder M. Dialogue control in automatic inquiry systems[C]//Spoken Dialogue Systems-Theories and Applications. 1995.
- [11] Goddeau D, Meng H, Polifroni J, et al. A form-based dialogue manager for spoken language applications[C]//Spoken Language, 1996. ICSLP 96. Proceedings., Fourth International Conference on. IEEE, 1996, 2: 701-704.
- [12] Williams J, Raux A, Ramachandran D, et al. The dialog state tracking challenge[C]//Proceedings of the SIGDIAL 2013 Conference. 2013: 404-413.

- [13] Henderson M, Thomson B, Williams J D. The second dialog state tracking challenge[C]//Proceedings of the 15th Annual Meeting of the Special Interest Group on Discourse and Dialogue (SIGDIAL). 2014: 263-272.
- [14] 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.
- [15] Henderson M, Thomson B, Young S. Robust dialog state tracking using delexicalised recurrent neural networks and unsupervised adaptation[C]//Spoken Language Technology Workshop (SLT), 2014 IEEE. IEEE, 2014: 360-365.
- [16] Mrkšić N, Séaghdha D O, Wen T H, et al. Neural belief tracker: Data-driven dialogue state tracking[J]. arXiv preprint arXiv:1606.03777, 2016.
- [17] Ramadan O, Budzianowski P, Gašić M. Large-scale multi-domain belief tracking with knowledge sharing[J]. arXiv preprint arXiv:1807.06517, 2018.
- [18] Dai A M, Le Q V. Semi-supervised sequence learning[C]//Advances in neural information processing systems. 2015: 3079-3087.
- [19] Peters M E, Neumann M, Iyyer M, et al. Deep contextualized word representations[J]. arXiv preprint arXiv:1802.05365, 2018.
- [20] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//Advances in neural information processing systems. 2017: 5998-6008.
- [21] Budzianowski P, Wen T H, Tseng B H, et al. Multiwoz-a large-scale multi-domain wizard-of-oz dataset for task-oriented dialogue modelling[J]. arXiv preprint arXiv:1810.00278, 2018.



李舟军 (1963-), 通讯作者, 博士, 教授, 博士生导师。CCF 高级会员, 主要研究领域为数据挖掘与自然语言处理、网络与信息安全。

Email: lizj@buaa.edu.cn



张家培 (1995-), 硕士研究生, 主要研究领域为自然语言处理与对话系统。

Email: zhangjiawei@buaa.edu.cn