

文章编号: 2095-2163(2022)06-0078-06

中图分类号: TP391.1

文献标志码: A

# 基于 ColBert-EL 和 MRC 模型的零样本实体链接

王雪莹, 程路易, 徐波

(东华大学 计算机科学与技术学院, 上海 201620)

**摘要:** 本论文研究零样本实体链接任务。当前的两阶段方法主要存在 2 个问题: (1) 在候选实体生成阶段, 由于过分追求效率, 没有充分考虑指称项所在文本和实体摘要之间的交互, 导致召回率不高; (2) 在候选实体排序阶段, 只是单独地考虑了每个候选实体和指称项的关系, 这在一定程度上影响了整体的精度。针对这些问题, 本文提出了一种基于 ColBert-EL 和 MRC 模型的零样本实体链接方法。在候选实体生成阶段, 提出了一个基于 ColBert 的变种方法—ColBert-EL, 既可以指称项所在文本和实体摘要进行充分交互, 又可以快速地检索。在候选实体排序阶段, 将其建模成一个多项选择问题, 并提出了一个基于机器阅读理解的模型来对结果进行统一排序。实验结果验证了本文提出方法的有效性。

**关键词:** 零样本; 实体链接; 候选实体生成; 候选实体排序; 阅读理解模型

## Zero-shot entity linking based on ColBert-EL and MRC model

WANG Xueying, CHENG Luyi, XU Bo

(College of Computer Science and Technology, Donghua University, Shanghai 201620, China)

**【Abstract】** This paper studies the zero-shot entity linking task. The current two-stage method has two main problems: (1) in the candidate generation stage, due to excessive pursuit of efficiency, the interaction between the context where the mention is in and the entity description is not fully considered, resulting in a low recall; (2) the candidate ranking stage only considers the relationship between each candidate entity and the mention individually, which affects the overall accuracy to a certain extent. In response to these problems, this paper proposes a zero-shot entity linking method based on ColBert-EL and MRC models. In the stage of candidate generation, the paper proposes ColBert-EL model—a variant method based on ColBert, which can fully interact with the text of the mention and the entity description, and can also be retrieved quickly. In the candidate ranking stage, the paper models it as a multiple choice problem and proposes a model based on machine reading comprehension to rank the results uniformly. The experimental results verify the effectiveness of the method proposed in this paper.

**【Key words】** zero shot; entity linking; candidate generation; candidate ranking; reading comprehension model

## 0 引言

实体链接任务的目的是将文本中的实体指称项链接到知识库中对应的实体, 是许多信息抽取<sup>[1]</sup>和自然语言理解<sup>[2]</sup>等应用的重要组成部分, 因其解决了命名实体的词汇歧义。传统的实体链接解决方案通常假定在测试中要链接的实体在训练过程中已经见过, 但是在实际应用中, 这种假设往往并不成立。要链接的实体往往在训练集中没有出现过, 并且每个实体也没有很多的结构化先验信息, 如别名表、先验概率、结构化数据等<sup>[3]</sup>, 仅有一段关于实体的摘要信息。这种情况被称为零样本实体链接。

当前零样本实体链接方法主要采取两阶段的策略<sup>[4]</sup>, 如图 1 所示, 第一阶段是候选实体生成, 其目标是快速找到文本中实体指称项在知识库中的候选实体集合; 第二阶段是候选实体排序, 其目标是对候

选实体进行精准的重排序, 并返回得分最高的实体作为指称项匹配的实体。然而, 这些方法主要存在 2 个问题。第一个问题是在候选实体生成阶段, 由于过分追求效率, 对指称项所在文本和实体摘要进行单独编码, 没有充分考虑两者之间的交互, 导致召回率不高; 第二个问题是在实体排序阶段, 只是单独地考虑了每个候选实体和指称项的关系, 未将所有候选实体作为一个整体进行考虑, 这在一定程度上影响了整体的精度。

综前问题所述, 本文提出了一种基于 ColBert-EL 和 MRC 模型的零样本实体链接方法。在候选实体生成阶段, 针对指称项所在文本和实体摘要缺乏交互的问题, 提出了一个基于 ColBert<sup>[5]</sup>的变种方法—ColBert-EL, 既可以指称项所在文本和实体摘要进行充分交互, 又可以快速地检索。在候选实体排序阶段, 针对所有候选实体没有整体考虑的问题, 本文

**作者简介:** 王雪莹(1997-), 女, 硕士研究生, 主要研究方向: 自然语言处理、实体链接; 程路易(1993-), 男, 硕士研究生, 主要研究方向: 自然语言处理、对话系统; 徐波(1988-), 男, 博士, 讲师, 硕士生导师, 主要研究方向: 知识图谱、自然语言处理、人工智能等。

收稿日期: 2021-12-13

哈尔滨工业大学主办 ◆ 学术研究与应用

将其建模成一个多项选择问题,并提出了一个基于机器阅读理解模型来对结果进行统一排序。

研究中,在公开的零样本实体链接数据集 ZESHEL<sup>[6]</sup>上进行了实验,与基线方法的结果相比,

在候选实体生成阶段,召回率提升了 5.9%,在候选实体排序阶段,准确率提升了 4.12%。实验结果验证了本文提出方法的有效性。

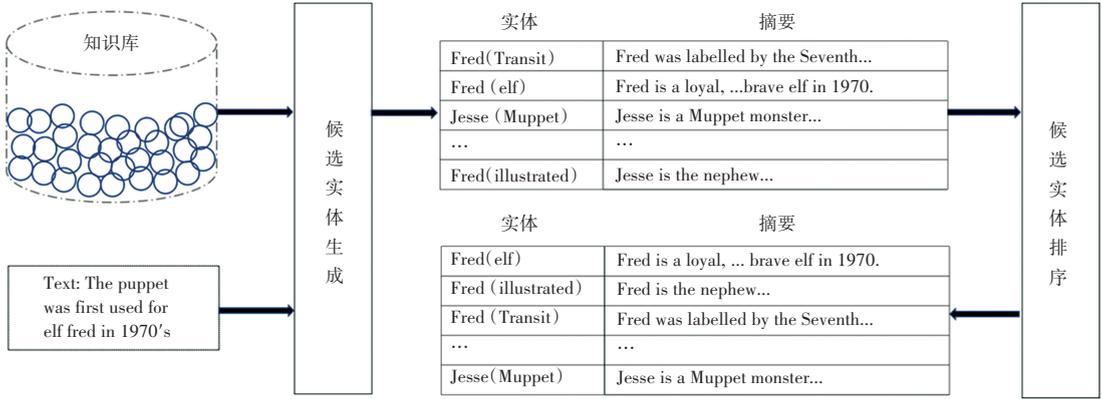


图 1 两阶段零样本实体链接方法

Fig. 1 Two-stage zero-shot entity linking method

## 1 相关工作

零样本实体链接可以分为候选实体生成和候选实体排序两个阶段。在候选实体生成阶段,主要分为基于词义的方法和基于语义的方法。例如,文献[6]中使用 BM25 基于词义的方法来生成候选实体。但这种方法存在词汇不匹配问题,这会导致模型在一开始就把正确答案排除在外,导致召回率过低,在后一阶段即使使用复杂的模型也无法找到正确答案。文献[7]中使用了 BERT 等基于语义的方法来生成候选实体。基本思路是将指称项所在文本和实体摘要使用 BERT 进行单独编码,最后计算两者的相似性。然而这种方法没有充分考虑两者之间的交互,依然会导致召回率不高。

在候选实体排序阶段,目前的零样本实体链接方法主要采用 Cross - encoder 的方法进行重排序<sup>[6-7]</sup>。研究时将实体指称项所在文本和每个候选实体的摘要进行拼接后,利用 Bert 编码器得到拼接后句子的编码,再通过一个全连接层输出匹配的分數。最后取所有候选实体中分数最大者作为当前实体指称项应该链接的实体。但是这种方法是单独考虑每一个候选实体的,在整体的精度上的表现有待加强。

## 2 方法

### 2.1 任务定义

零样本实体链接任务是在给定一个仅包含实体

摘要信息的知识库前提下,将一个文本中出现的实体指称项链接到该知识库中的实体上去,并且测试集中的实体所在领域和训练集中实体所在领域不同。零样本实体链接问题的形式化定义如下:给定一个仅包含实体摘要信息的知识库  $\Psi = \{(e_i, desc_i)\}_{i=1}^n$ , 这里  $e_i$  表示知识库中的第  $i$  个实体,  $desc_i$  表示知识库中第  $i$  个实体的摘要。某一领域内的实体指称项语料集合为  $D = \{(m_j, text_j)\}_{j=1}^l$ , 其中  $text_j$  表示一段文本,  $m_j$  表示这段文本中出现的一个实体指称项。零样本实体链接系统的目标是从知识库中找出文本中出现的实体指称项  $m_j$  对应的实体  $e^*$ 。

### 2.2 候选实体生成

本文提出了一种基于 ColBert<sup>[5]</sup>的变种方法 - ColBert-EL 用于生成候选实体。ColBert 最早用于信息检索领域,主要用于估计查询和文档的相关性。其基本思路是先对文本中的每个词向量和实体摘要中的每个词向量进行独立编码,然后采用一种后期交互(Late Interaction)的方式来计算指称项和候选实体的相似度,考虑到了匹配的效率和,又让文本和摘要进行了充分交互。本文对其原始模型的输入进行了重新设计,使其能够用于实体链接任务。ColBert-EL模型结构如图 2 所示。

对于每个实体指称项,其具体表示形式为:

$$[CLS] [M] ctxt_l < m > mention < /m > ctxt_r [SEP]$$

其中,  $mention$  表示实体指称项;  $ctxt_l$  和  $ctxt_r$  分别表示文档中  $mention$  的左右上下文;  $< m >$  和

$\langle /m \rangle$  是标记实体指称项的特殊词。文中在  $[CLS]$  位右边放置特殊词  $[M]$  来表明这是一个实体指称项所在文本的输入序列。实体指称项相关信息

的输入序列分词后的形式是  $T_m = [m_1, m_2, \dots, m_n], n = |T_m|$ 。将  $T_m$  送入到编码器中编码得到  $E_m = [m'_1, m'_2, \dots, m'_n]$ 。

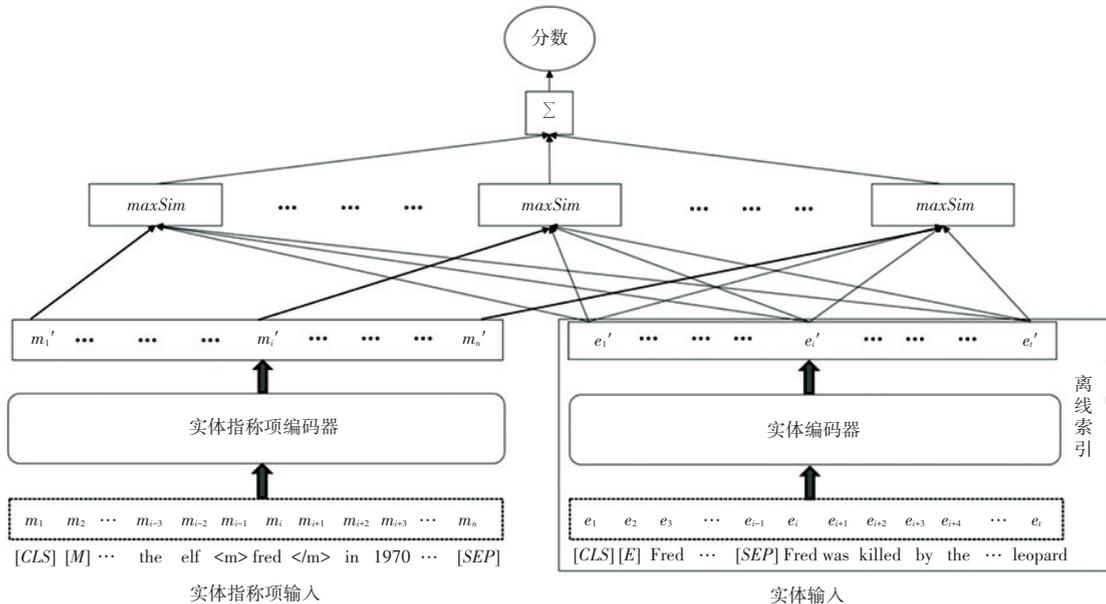


图2 ColBert-EL 模型结构图

Fig. 2 Structure diagram of ColBert-EL model

实体及其摘要的具体输入形式为:

$[CLS] [E] title [ENT] description$

其中,  $title$ ,  $description$  分别是实体名称和实体摘要分词后的形式,  $[ENT]$  是用来分隔实体名称和实体摘要的特殊标志。这里用  $[E]$  来表明输入的是实体摘要。实体相关信息输入序列分词后的形式是  $T_e = [e_1, e_2, \dots, e_t], t = |T_e|$ 。将  $T_e$  送入编码器编码后得到输出向量  $E_e = [e'_1, e'_2, \dots, e'_t]$ 。

得到实体指称项和实体相关词向量的编码后, 编码器将输出编码通过一个没有激活函数的线性层。该层减小每个词向量编码的输出维度, 使其小于 Bert 编码器的隐藏层维度, 用于控制 ColBert-EL 的计算成本。最后, 每一个输出编码将会用  $L_2$  范式被归一化。这样做的优点是任意 2 个编码的点积的结果将落在  $[-1, 1]$  范围内, 等同于两者的余弦相似度。

综上, 当给出  $T_m = [m_1, m_2, \dots, m_n], T_e = [e_1, e_2, \dots, e_t]$  后, 得到实体指称项和实体编码的方式如下:

$$E_m = \text{Normalize}(\text{Linear}(\text{Bert}(T_m))) \quad (1)$$

$$E_e = \text{Normalize}(\text{Linear}(\text{Bert}(T_e))) \quad (2)$$

当得到实体指称项和实体相关信息的编码后, 利用公式(3)计算实体与当前实体指称项的相关性分数:

$$S_{m,e} = \sum_{i \in |E_m|} \max_{j \in |E_e|} \text{maxSim}(E_{m_i} \cdot E_{e_j}) \quad (3)$$

也就是, 先计算实体指称项的每一个词编码与实体所有词向量编码的余弦相似度, 选出最大者作为实体指称项当前词编码的最大相似度分数。将实体指称项每一个词编码的最大余弦相似度分数相加, 便得到当前实体与实体指称项的相关性分数。

### 2.3 候选实体排序

候选实体排序的目标是对实体指称项的每个候选实体进行重新排序, 选出与实体指称项相关性最大的候选实体, 并将其当作实体指称项应该链接的实体。该过程的输出结果直接决定了整体框架的好坏。因此, 本文使用了一个基于机器阅读理解 (MRC) 的模型来充分考虑指称项文本和候选实体摘要之间的交互, 并且考虑了全部的候选实体。MRC 模型结构如图 3 所示。

具体来说, 对于每一个候选实体, 研究将实体的摘要信息和指称项所在文本进行拼接, 拼接结果如下所示:

$[CLS] [M] ctxt_l \langle m \rangle mention \langle /m \rangle$   
 $ctxt_r [SEP] [E] title [ENT] description$

这种输入形式使得实体指称项和候选实体的信息通过编码器得到更深层次的交互, 更好地捕捉到实体指称项和实体之间的语义信息和句法特征, 从而能够更好地完成链接的任务。

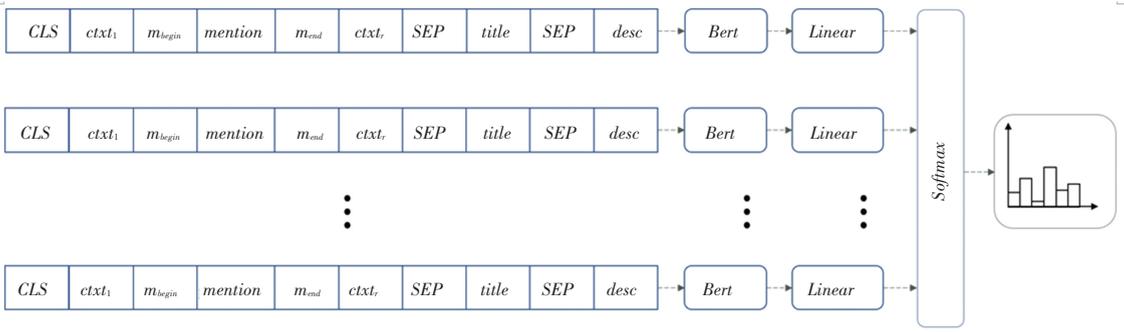


图 3 MRC 模型结构图

Fig. 3 Structure diagram of MRC model

此后,研究将输入送进 Bert 编码器得到每个词向量的编码,再取其中第一位 *CLS* 的输出送入一个 *Linear* 线性层,最终得到一个标量、即候选实体与实体指称项的相关性分数,具体计算见公式(4):

$$S_{m,e} = Linear(red(Bert(T_{me}))) \quad (4)$$

其中,  $T_{me}$  是实体指称项与实体拼接后的输入;  $Bert(\cdot)$  是将输入进行编码的编码器;  $red(\cdot)$  是只保留第一位 *CLS* 编码的函数;  $Linear(\cdot)$  是将一维向量转变为标量的线性层。

为了通盘考虑全部的候选实体,将全部候选实体的相关性分数输入到一个 *Softmax* 层,并取得得分最高的候选实体作为实体指称项应该链接的实体。计算公式如下所示:

$$e^* = arg \max_{e^u} \frac{\exp(S_{m,e^u})}{\sum_{v=1}^{64} \exp(S_{m,e^v})} \quad (5)$$

其中,  $e^u$  表示第  $u$  个候选实体。

### 2.4 训练

ColBert-EL 模型的训练过程如下:模型的输入是三元组  $\langle m, e^+, e^- \rangle$ , 这里  $m$  是实体指称项及其上下文,  $e^+$  是实体指称项的正例实体,  $e^-$  是实体指称项的负例实体。正例实体是由数据集给定的,而负例实体是通过 TF-IDF 技术<sup>[8]</sup> 计算得到的,是和正确实体的摘要最相似的 7 个实体摘要。ColBert-EL 模型是一个二分类任务,模型参数是通过二元交叉熵损失函数来进行优化的。

MRC 模型的训练过程如下:构建了 2 种不同的训练集来训练 MRC 模型。第一种是通过用 ColBert-EL 模型生成的候选实体来训练 MRC,第二种是通过用 TF-IDF 技术生成的候选实体来训练 MRC。在对 MRC 进行训练时,如果数据中实体指称项的正确实体不包含于候选实体集合中,则将丢弃这条数据。由于利用 TF-IDF 技术生成的候选实体集合中实体指称项的候选实体个数并不总是相同

的,就可将候选实体个数相同的实体指称项数据放到一个批次中,用于对 MRC 模型的训练。本文构建模型的参数是通过交叉熵损失函数来优化的,其中负例是候选实体集合中的所有非正例实体。

### 2.5 检索优化

ColBert-EL 模型采用后期交互的方式,对每个可能的实体进行详尽的评估是极其消耗计算资源的。由于文中只关注其中分数较高的部分实体,为了加快检索效率,先通过一个粗粒度的匹配算法快速从整个实体集合的离线索引中找到 Top -  $K$  个相似实体,再使用 ColBert-EL 算法对这些实体进行相似度计算。

具体来说,使用了 Facebook 的 Faiss (Facebook AI Similarity Search)<sup>[9]</sup> 库来对实体摘要中的每个词向量的编码进行存储。在第一个阶段,先以指称项所在文本中的每个词向量的编码作为查询,然后从 Faiss 库中找到与每个词向量最相似的 Top -  $K'$  个实体摘要,最终对一个实体指称项来说,共得到  $N \times K'$  个实体摘要,其中  $K' = \frac{K}{2}$ ,  $N$  为实体指称项中词向量的数量。这里使用了 IVFPQ 索引 (inverted file with product quantization)<sup>[10]</sup>。接下来,针对统计得到的这些实体摘要,选择出现次数最多的 Top -  $K$  个实体作为快速检索的结果。在第二个阶段,则通过 ColBert-EL 算法对 Top -  $K$  个实体进行重新排序,并返回 Top -  $K$  个结果。

在第二个阶段,则通过 ColBert-EL 算法对 Top -  $K$  个实体进行重新排序,并返回 Top -  $K$  个结果。

## 3 实验

### 3.1 实验准备

本文实验中使用的数据集是 ZESHEL,这是由文献[6]在提出零样本实体链接任务时从维基百科文档中创建的。数据集一共划分了 16 个领域,每个领域内的实体数量范围从 10 k 到 100 k 不等。训练集、验证集、测试集分别拥有 8、4、4 个不同的领域,包含的实体指称项个数分别是 49 k、10 k、10 k。研究中选用 Bert-base<sup>[11]</sup> 作为 ColBert-EL 模型和 MRC

模型的基础编码器,选用 AdamW<sup>[12]</sup> 作为优化器。

### 3.2 对比方法

本文的方法主要是评估零样本实体链接系统的链接性能。研究时分别评估了两阶段模型的表现并与目前最优的方案做比较。在候选实体生成阶段,与文献[6]提出的 BM25 模型和文献[7]提出的 Bi-encoder 模型进行比较;在候选实体排序阶段,又与文献[7]中的 Cross-encoder 模型进行了比较。

### 3.3 评估指标

模型预测的结果最终会被归为以下4类: *TP* 为将正类预测为正类数; *TN* 为将负类预测为负类数; *FP* 为将负类预测为正类数; *FN* 为将正类预测为负类数。

对候选实体生成模型评估的指标为召回率 (*Recall*),该值可由如下计算公式求得:

$$Recall = \frac{TP}{TP + FN} \quad (6)$$

对候选实体排序模型评估的指标为 *Normalized Accuracy* 和 *Unnormalized Accuracy*。 *Accuracy* 的计算公式可写为:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

*Normalized* 是对候选实体集合中包含正确实体的测试集中的样例在实体链接系统上的表现,即评估时不考虑那些候选实体集合中不包含正确实体的测试集实体指称项数据。而 *Unnormalized* 是指实体链接系统在所有测试集上的表现。

### 3.4 候选实体生成实验评估

ColBert-EL 模型在训练集上训练之后,挑选在验证集上表现最好的模型用来对测试集数据进行测试。在候选实体的选取中,基线选择将实体输入的 *CLS* 位编码与实体指称项输入的 *CLS* 位编码做点积以获取两者之间的相似度。与之相比,研究中充分利用了实体指称项和实体输入的每一位词向量的编码表示,计算了每一个可能的实体与实体指称项之间的相关性。同时,复现了基线的模型,并得到了基线模型在测试集4个领域的表现。实验证明,本文提出的模型精度优于基线,测试集总体表现详见表1,各个领域表现详见表2。

表1 训练集/测试集前64位召回率

Tab. 1 Recall@64 on train/ test set %

	Train	Test
BM25 <sup>[6]</sup>	76.86	69.13
Bi-encoder <sup>[7]</sup>	88.65	79.71
ColBert-EL	91.10	85.61

表2 测试集各领域前64位的召回率

Tab. 2 Recall@64 on each domain within test set %

	forgotten_realms	lego	star_trek	yugioh
Bi-encoder <sup>[7]</sup>	90.33	90.49	81.17	70.27
ColBert-EL	93.67	89.32	84.36	82.99

### 3.5 候选实体排序实验评估

在用 ColBert-EL 模型为每个实体指称项评估完前 *k* 个实体,并得到64个候选实体后,就在这些候选实体上训练了 MRC 模型,且在测试集上对 MRC 模型进行了测试,结果见表3。由表3可知,本文研究在端到端的精度上超越了基线的精度。

表3 MRC 模型非标准化精度

Tab. 3 The Unnormalized Accuracy of MRC model

方法	Test ( <i>U.Acc</i> )
BM25 <sup>[6]</sup>	55.08
Cross-encoder <sup>[7]</sup>	61.34
ColBert-EL	65.46

为了进一步验证 MRC 模型的有效性,研究又在文献[7]提供的候选实体集上对 MRC 进行了训练。由于在用 TF-IDF 技术为实体指称项生成实体的时候,每个实体指称项的候选实体个数不总是一致的,因此本文将候选实体个数相同的数据放到同一批次中进行训练。具体的分数见表4。

表4 MRC 模型标准化精度

Tab. 4 The Normalized Accuracy of MRC model

方法	Validation ( <i>Acc</i> )	Test ( <i>Acc</i> )
BM-25 <sup>[6]</sup>	76.06	75.06
Cross-encoder <sup>[7]</sup>	75.06	76.56
ColBert-EL	76.56	78.24

## 4 结束语

本文提出了一种基于 ColBert-EL 和 MRC 模型的零样本实体链接方法。在候选实体生成阶段,为了加快检索效率,研究中先通过一个粗粒度的匹配算法快速从整个实体集合的离线索引中找到 Top-*K* 个相似实体,再使用 ColBert-EL 算法对这些实体进行相似度计算。在候选实体排序阶段,则考虑了全部的候选实体,将其建模成一个多项选择问题,提出了一个基于机器阅读理解的模型来对结果进行统一排序。本次研究中在零样本实体链接数据集 ZESHEL 上分别对候选实体生成和候选实体排序两阶段的效果进行评估,实验结果验证了本文提出方法的有效性。

## 参考文献

- [1] LI Xuansong, STRASSEL S, JI Heng, et al. Linguistic resources for entity linking evaluation: From monolingual to cross-lingual [C]// Proceedings of the Eighth International Conference on Language Resources and Evaluation (LREC'12). Istanbul: ELRA, 2012: 3098-3105.
- [2] GANEA O E, GANEA M, LUCCHI A, et al. Probabilistic bag of -hyperlinks model for entity linking[C]//Proceedings of the 25<sup>th</sup> International Conference on World Wide Web. Montreal, Canada: ACM, 2016:927-938.
- [3] YAO Zonghai, CAO Liangliang, PAN Huapu. Zero-shot entity linking with efficient long range sequence modeling [C]// Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing. ACL, 2020:2517-2522.
- [4] GILLICK D, KULKARNI S, LANSING L, et al. Learning dense representations for entity retrieval [C]// Proceedings of the 23<sup>rd</sup> Conference on Computational Natural Language Learning (CoNLL). Hong Kong, China: ACL, 2009:528-537.
- [5] KHATTAB O, ZAHARIA M. Colbert: Efficient and effective passage search via contextualized late interaction over bert [C]// Proceedings of the 43<sup>rd</sup> International ACM SIGIR Conference on Research and Development in Information Retrieval. ACM, 2020: 39-48.
- [6] LOGESWARAN L, CHANG M W, LEE K, et al. Zeroshot entity linking by reading entity descriptions [C]// Proceedings of the 57<sup>th</sup> Annual Meeting of the Association for Computational Linguistics. Florence, Italy: ACL, 2019:3449-3460.
- [7] WU L, PETRONI F, JOSIFOSKI M, et al. Scalable zero-shot entity linking with dense entity retrieval [C]// Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). Bloomberg, Google, 2020:6397-6407.
- [8] AIZAWA A. An information-theoretic perspective of TF-IDF measures [J]. Information Processing & Management, 2003, 39 (1):45-65.
- [9] JOHNSON J, DOUZE M, JEGOU H. Billion-scale similarity search with gpus [J]. IEEE Transactions on Big Data, 2021, 7 (3):535-547.
- [10] BARANCHUK D, BABENKO A, MALKOV Y. Revisiting the inverted indices for billion scale approximate nearest neighbors [C]// Proceedings of the European Conference on Computer Vision (ECCV). Munich, Germany: Amazon, 2018:202-216.
- [11] DEVLIN J, CHANG Mingwei, LEE K, et al. Bert: Pre-training of deep bidirectional transformers for language understanding [C]// Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics; Human Language Technologies, Volume 1 (Long and Short Papers). Minneapolis, Minnesota: ACL, 2019:4171-4186.
- [12] LLUGSI R, YACOUBI E L, FONTAINE S, et al. Comparison between adam, adamax and adam w optimizers to implement a weather forecast based on neural networks for the andean city of quito [C]// 2021 IEEE Fifth Ecuador Technical Chapters Meeting (ETCM). Cuenca, Ecuador: IEEE, 2021:1-6.

(上接第 77 页)

## 4 结束语

本文利用 TC277 芯片的丰富资源和 elmos 高性能探头 IC, 配置 IC 各个参数并基于实时矫正算法设计了 12 路超声波雷达自动泊车测距与定位系统, 应用于泊车 ECU 中, 经过实车对前方 4 个短距超声波雷达的功能测试, 在 20~250 cm 范围内可将测量精度提高到 1.5 cm, 证明该算法较大地提高了检测精度, 可适应于复杂环境中的泊车应用, 为实现视觉与超声波雷达数据融合以进行可视化距离检测提供有效帮助<sup>[12]</sup>。

## 参考文献

- [1] YANG Jianchen, LIU Shan, SU Hansong, et al. Driving assistance system based on data fusion of multisource sensors for autonomous unmanned ground vehicles [J]. Computer Networks, 2021 (21): 1080.
- [2] 苑洁. 基于 STM32 单片机的高精度超声波测距系统的设计 [D]. 北京: 华北电力大学, 2012.
- [3] 苑洁, 常太华. 基于 STM32 单片机的高精度超声波测距系统的设计 [J]. 电子设计工程, 2011, 19(15): 76-78, 82.
- [4] 隋卫平. 高精度实时超声测距技术研究 [D]. 合肥: 国防科学技术大学, 2003.
- [5] 曾祥进, 王敏, 黄心汉. 自动增益电路在超声波测距系统中的应
- 用研究 [J]. 测控技术, 2005(07): 69-71.
- [6] 潘仲明, 祝琴. 压电换能器阻抗匹配技术研究 [J]. 应用声学, 2007(06): 357-361.
- [7] 周玲, 高怀, 刘梦莹, 等. 基于单片机的自动泊车系统设计 [J]. 山西大同大学学报 (自然科学版), 2021, 37(01): 19-22, 118.
- [8] 谢地, 鲁照权, 丁浩峰, 等. 基于超声波测距的高精度室内定位系统 [J]. 传感器与微系统, 2019, 38(10): 98-101.
- [9] 燕学智, 王子婷, 王昕. 超声波三维定位系统中基线长度与误差传递关系的分析 [J]. 吉林大学学报 (工学版), 2021, 51(04): 1461-1469.
- [10] 刘芬, 罗前刚, 张远征. 高精度超声波测距方法的研究 [J]. 自动化与仪表, 2021, 36(05): 66-69.
- [11] 张海焕, 陈彩霞, 马逸行. 基于超声波雷达的自动泊车自适应测距与定位设计 [J]. 科技视界, 2020(28): 1-4.
- [12] 陈建明, 曹晨航, 陈俊宇. 长距超声波雷达在汽车智能泊车系统中的测距研究 [J]. 西昌学院学报 (自然科学版), 2020, 34(02): 62-65.
- [13] ELMOS. 2<sup>nd</sup> Generation Ultrasonic Transducer Driver and Signal Processor E524.08 / E524.09 [EB/OL]. [2015-09-17]. Http://WWW.ELMOS.DE.
- [14] 杨令晨, 周武能, 汤文兵, 等. 超声波测距系统的研究及其硬件设计 [J]. 仪表技术与传感器, 2018(02): 41-47.
- [15] WU T F, TSAI P S, HU N T, et al. Research and implementation of auto parking system based on ultrasonic sensors [C]// 2016 International Conference on Advanced Materials for Science and Engineering (ICAMSE). Taiwan: IEEE, 2016:643-645.