



计算机工程
Computer Engineering
ISSN 1000-3428, CN 31-1289/TP

《计算机工程》网络首发论文

题目： 基于多策略强化学习的低资源跨语言摘要方法研究
作者： 冯雄波，黄于欣，赖华，高玉梦
DOI： 10.19678/j.issn.1000-3428.0067225
网络首发日期： 2023-05-29
引用格式： 冯雄波，黄于欣，赖华，高玉梦. 基于多策略强化学习的低资源跨语言摘要方法研究[J/OL]. 计算机工程. <https://doi.org/10.19678/j.issn.1000-3428.0067225>



网络首发：在编辑部工作流程中，稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定，且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式（包括网络呈现版式）排版后的稿件，可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定；学术研究成果具有创新性、科学性和先进性，符合编辑部对刊文的录用要求，不存在学术不端行为及其他侵权行为；稿件内容应基本符合国家有关书刊编辑、出版的技术标准，正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性，录用定稿一经发布，不得修改论文题目、作者、机构名称和学术内容，只可基于编辑规范进行少量文字的修改。

出版确认：纸质期刊编辑部通过与《中国学术期刊（光盘版）》电子杂志社有限公司签约，在《中国学术期刊（网络版）》出版传播平台上创办与纸质期刊内容一致的网络版，以单篇或整期出版形式，在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊（网络版）》是国家新闻出版广电总局批准的网络连续型出版物（ISSN 2096-4188，CN 11-6037/Z），所以签约期刊的网络版上网络首发论文视为正式出版。



基于多策略强化学习的低资源跨语言摘要方法研究

冯雄波^{1,2}, 黄于欣^{1,2}, 赖华^{*1,2}, 高玉梦^{1,2}

(1. 昆明理工大学 信息工程与自动化学院 云南 昆明 650504;

2. 昆明理工大学 云南省人工智能重点实验室 云南 昆明 650504)

摘要：跨语言摘要 (CLS) 旨在给定一个源语言文件 (如越南语), 生成目标语言 (如中文) 的摘要。最近, 端到端的 CLS 模型在大规模、高质量的标记数据基础上取得了相当良好的性能, 这些标记数据通常是利用机器翻译模型将单语摘要语料库翻译成 CLS 语料库而构建的。然而, 由于低资源语言翻译模型的性能受限, 翻译噪音会被引入到 CLS 语料库中, 这严重损害了 CLS 的模型性能。因此, 提出利用多策略强化学习来解决低资源噪声训练数据场景下的 CLS 模型训练问题, 引入源语言摘要作为额外的监督信号来缓解翻译后的噪声目标摘要影响。具体来说, 首先通过计算源语言摘要和生成目标语言摘要之间的单词相关性和单词缺失程度来学习强化奖励, 然后在交叉熵损失和强化奖励的约束下优化 CLS 模型。为验证所提出模型的性能, 构建了一个有噪声的汉越 CLS 语料库, 根据实验结果在汉语-越南语跨语言摘要数据集和越南语-汉语跨语言摘要数据集上, 所提出的模型 ROUGE 分数明显优于其他基线模型, 相比 NCLS 基线模型, 该模型 RG-1 分别提升了 0.71 和 0.84 个点, 提出的方法能够有效弱化噪声干扰, 提高生成摘要的质量。

关键词：汉越跨语言摘要; 低资源; 噪声数据; 噪声分析; 多策略强化学习

开放科学 (资源服务) 标志码 (OSID):



Low-resource Cross-Lingual Summarization with Multi-Strategy Reinforcement Learning

Feng Xiongbo^{1,2} Huang Yuxin^{1,2} Lai Hua^{*1,2} Gao Yumeng^{1,2}

(1. Faculty of Information Engineering and Automatic, Kunming University of Science and Technology, Kunming 650504, Yunnan, China;

2. Yunnan Key Laboratory of Artificial Intelligence, Kunming University of Science and Technology, Kunming 650504, Yunnan, China)

【Abstract】 Cross-lingual summarization (CLS) aims at generating summary in a target language (e.g., Chinese) given a source language document (e.g., Vietnamese). Recently, end-to-end CLS models have achieved considerable results based on large-scale and high-quality labeled data, which is usually constructed by translating a monolingual summary corpus to a CLS corpus. However, due to the limited performance of low-resource language translation model, translation noisy will be introduced into the CLS corpus, which seriously damage the performance. This paper focus on tackling with the low-resource CLS based on noisy training data by using a multi-strategy reinforcement learning, where the source language summary is introduced as gold signal to alleviate the impact of the translated noisy target summary. Specifically, this paper learn a reinforcement reward by calculating the word correlation and word missing degree between the source language summary and the generated target language summary, and optimize the CLS model under the constrain of cross entropy loss and reinforcement reward. To verify the performance of proposed model, this paper construct a noisy Chinese-Vietnamese CLS corpus. The experimental results on the Chinese-Vietnamese cross-language summary dataset and the Vietnamese-Chinese cross-language summary dataset show that the ROUGE score of the proposed model is significantly better than other baseline models, and the RG-1 of the model is improved by 0.71 and 0.84 points, respectively, compared with the NCLS baseline model, and the proposed method can effectively mitigates noise interference and enhances the quality of generated summaries.

【Key words】 Chinese-vietnamese cross-language summary; Low resource; Noisy data; Noise analysis; Multi-policy reinforcement

基金项目：国家自然科学基金 (U21B2027)、云南省重大科技专项项目 (202202AD080003)、云南省基础研究计划面上项目 (202201AT070915, 202201AT070768)、昆明理工大学“双一流”创建联合专项 (202201BE070001-021)

作者简介：冯雄波, 1997、男、硕士、主研方向: 自然语言处理; 黄于欣, 博士; 赖华, 副教授; 高玉梦, 硕士。

E-mail: 405904235@qq.com

learning

DOI:10.19678/j.issn.1000-3428.0067225

0 引言

数据是直接决定能否训练出高性能的神经网络模型的关键因素,使用大规模、高质量的跨语言摘要数据训练有利于模型生成更高质量的摘要毋庸置疑的,但在跨语言摘要中数据稀缺是一个公认的问题^[1]。目前在跨语言摘要生成研究工作中,大多使用单语翻译构造的跨语言摘要数据。此类方法简单便捷,但在像越南语这种资源匮乏的语言上,机器翻译的表现并不理想。因此,使用翻译方法来构建汉越跨语言摘要的数据会产生较大的噪声。近年来的研究表明^[2,3],相比与传统的统计模型,神经网络模型对噪声数据十分敏感。由此,Zhu 等人^[2]在汉英跨语言摘要上提出采用数据筛选的方法提升机器翻译构造的跨语言摘要数据的质量。相比汉英来说,基于机器翻译构造的汉越跨语言摘要数据噪声更大,对数据过滤时既要保证数据的质量又要保证数据的数量,即使过滤掉一部分错误严重的噪声数据后,留下的数据集仍无法避免噪声。由此,本文针对汉越跨语言摘要,进行不同情况下的数据进行噪声分析与研究,并针对主要噪声类型提出不同的优化策略。

在序列到序列的跨语言摘要模型中,常使用生成摘要与伪目标摘要的交叉熵损失来优化模型参数,而该方法无法避免伪目标摘要中存在的噪声对模型带来的错误指导。对此,Dou 等人^[4]认为使用机器翻译的源语言摘要-伪目标语言摘要训练模型时存在错误传播问题,于是提出直接使用源语言摘要与生成目标语言摘要间的句子相似度作为强化学习奖励约束模型更好的生成摘要。受到该工作启发,本文利用强化学习的思想,引入真实的源语言摘要来指导目标摘要的生成,改善噪声数据对模型的影响,生成质量更高的摘要。与他们不同的是:在强化学习策略方面,本文分析了伪目标摘要中存在的噪声类型,有针对性的从细粒度层面设计强化学习奖励期望。在训练数据方面,在汉语-越南语跨语言摘要数据集和越南语-汉语跨语言摘要数据集构建与筛选的过程中,产生了单语摘要数据、筛选前大规模的跨语言摘要噪声数据、筛选后一定规模的高质量数据。本文实现了对数据集的联合使用,除了引入单语数据中的真实的源语言摘要作为优化基准,本文还合理使用了另外两个数据集。基于单语数据翻译得到的大规模噪声数据,噪声数据会

带来错误指导问题,但在大规模的数据下训练有利于提高模型的泛化能力。由此,使用该数据对强化学习模型进行参数初始化,解决强化学习稳定性问题的同时,也可增加模型的泛化能力。最后,在基于一定规模的高质量数据的基础上,对本文提出的多策略强化学习的汉越跨语言摘要模型进行了进一步的优化。

本文以噪声数据为出发点,首先使用 Rouge^[5]、BERTScore^[6]与 Msftscore^[7]对单语翻译得到的伪汉越跨语言摘要数据进行噪声过滤,提高数据集质量。然后,对不同情况下的数据集进行噪声分析(具体分析在第2节中),可以发现无论是在汉语-越南语跨语言摘要数据集还是在越南语-汉语跨语言摘要数据集中,选词不当和实词缺失是最为常见的错误类型,它们分别占据最大的错误比例。由此,从多个层面考虑,提出多策略强化学习的汉越跨语言摘要,弱化噪声数据带来的错误指导。例如,源语言摘要“工商总局回应与淘宝争议...”,机器翻译为伪目标语言为“Cơ quan Quản lý Nhà nước về Công nghiệp và Thương mại giải quyết tranh chấp với Taobao(国家工商总局与淘宝纠纷处理)”。其中,“回应”一词被翻译为“giải quyết(处理)”。如果直接采用翻译不准确的伪摘要作为监督信号,会给模型带来错误指导。由此,针对选词不当,本文在解码器生成目标摘要词语时,通过与源语言摘要词相关性匹配设计强化学习奖励,避免翻译不准确的词带来的噪声影响。源语言摘要“期末临近海口小学生作业多家长担忧负担太重帮作弊”,机器翻译为伪目标语言为“Cuối kỳ, học sinh tiểu học Hải Khẩu có quá nhiều bài tập về nhà(海口小学生期末作业太多)”,可以看出翻译后越南语中漏掉了源语言摘要中“期末临近”、“家长担忧”、“帮作弊”等重要信息。如果直接使用这样的伪摘要计算损失函数,很大程度上弱化了生成摘要的全面性。由此,针对实词缺失,本文在解码器生成目标摘要词语时,以源语言摘要中词语为基准,根据缺失词语的重要程度设计缺失惩罚。另外,本文中并没有完全摒弃传统的交叉熵损失函数,而是使用交叉熵与强化学习相结合的方法优化模型。因为尽管伪目标语言中存在噪声,但中文与越南语之间存在着很大的语序差异,使用伪目标语言优化模型可以让模型学到句子中更多的逻辑关系。由此,本文采用不同策略从生成词相关性与缺失度组合设计强化学习奖励,同时,与

传统的交叉熵损失相结合, 构建目标函数来优化模型, 可以更有效地指导模型生成目标语言摘要。在本文的实验结果中, 证明了引入真实的源语言摘要来设计多策略强化学习方法, 能够有效提升跨语言摘要模型在噪声数据下的性能。

1 相关工作

1.1 跨语言摘要

跨语言摘要任务是输入汉语(越南语)文档自动生成越南语(汉语)简短摘要的任务。传统的跨语言摘要任务通常采用先翻译再摘要^[8]或者先摘要再翻译^[9-10]的技术框架, 但通常会受到翻译模型和摘要模型错误传递的影响, 在低资源语言上效果还不理想。基于神经网络的跨语言摘要任务通常将其看作一个类似机器翻译任务, 不同之处在于机器翻译的输入和输出的信息量不变, 而跨语言摘要需要对信息进行压缩和翻译。针对低资源语言跨语言摘要任务通常有两类方法: 第一类是基于零样本学习的摘要方法, Ayana 等人^[11]针对源语言文档到目标语言摘要数据集缺乏问题, 提出使用预先训练好的机器翻译模型与标题生成模型作为教师网络来指导跨语言标题生成模型, 同时学习翻译能力和摘要能力, 实现零样本条件下跨语言摘要生成。Duan 等人^[1]在沿用单语摘要模型作为教师网络来指导跨语言摘要模型参数学习的基础上, 在学生网络中增加了对教师网络的注意力权重的学习。第二类方法基于机器翻译和摘要的多任务联合学习方法, 利用机器翻译模型与单语摘要等模型联合训练来弥补训练数据稀缺问题。zhu 等人^[12]基于 Transformer 文本生成框架, 提出了端到端跨语言摘要模型, 跨语言摘要与单语摘要、跨语言摘要与机器翻译任务进行联合训练, 在编码端进行参数共享, 训练过程中两个任务进行交替训练学习跨语言摘要生成能力。此外, 他们还引入了 Round-Trip Translation Strategy (RTT) 的方法, 基于机器翻译模型对单语数据集进行翻译并使用 Rouge 进行打分过滤低质量翻译数据, 构造了中英语言对上的跨语言摘要数据集。Cao 等人^[13]为了实现更好的跨语言对齐, 利用生成对抗网络来对齐源语言与目标语言两个单语摘要模型中的上下文表征, 在进行单语摘要训练的同时达到双语对齐的目的。Bai 等人^[14]认为跨语言摘要与机器翻译联合学习的方法虽然可以通过共享编

码器参数来增强跨语摘要性能, 但两个任务的解码器相互独立, 无法很好的建立跨语言摘要与机器翻译任务的对齐, 因此, 该文提出一种解码器改进方法, 同时解码源语言和目标语言摘要, 提升解码器对两种语言的解码能力, 相比联合学习中使用两个独立解码器取得了更好的结果。以上工作大多基于机器翻译对单语数据集进行翻译构造伪平行的跨语言摘要数据集, 但都是中英等大语种, 机器翻译性能较好, 翻译错误较少, 但是对于低资源翻译效果有限语言研究较少, 对于机器翻译可能带来的噪声问题缺乏有效的分析和处理手段。

1.2 强化学习

强化学习在机器翻译、文本摘要等文本生成任务应用较多, 主要是通过全局解码优化来缓解曝光偏差问题^[15-16]。在摘要任务上, Paulus 等人^[17]提出将真实摘要与生成摘要间的 ROUGE 值作为强化学习奖励对模型进行奖励或惩罚, 使用线性差值的方式将该奖励与交叉熵相结合作为训练目标函数, 一定程度上缓解了曝光偏差问题。Böhm 等人^[18]认为 ROUGE 在词汇多样性表述的摘要上与人工评价相关性较差, 基于 ROUGE 值作为强化学习奖励的可靠性不高, 因此提出采用源文本和生成摘要作为输入从人工评分的摘要中学习奖励函数, 取得了相比与 ROUGE 值作为奖励更好的结果。Yoon 等人^[19]基于语言模型计算生成摘要与真实摘要间的语义相似度作为强化学习奖励, 改善了词粒度匹配 ROUGE 的奖励获取方式。针对跨语言摘要任务, Dou 等人^[4]提出用源语言摘要和生成的目标语言摘要间的相似度作为强化学习奖励来约束模型生成更好的摘要。受到该工作启发, 我们认为通过更好的建模源语言摘要和生成摘要之间的相关性, 能够很好的利用纯净没有噪声的源语言摘要来缓解翻译带来的噪声问题。

2 数据分析

2.1 数据集构建

在本文分别构建了汉语-越南语跨语言摘要以及越南语-汉语跨语言摘要两个数据集。在汉语-越南语跨语言摘要数据集中, 采用 LCSTS^[20]前 20 万数据进行回译得到汉语-越南语跨语言摘要数据集 (Zh-Visum)。越南语-汉语跨语言摘要数据集是通过从越南网 (Vietnam+)、越南新闻社、越南快讯、越南通讯社等多个新闻网站收集

越南语单语数据集，并进行清洗和翻译得到的，最终获得了约 11.5798 万条越南语-汉语跨语言摘要数据集 (Vi-Zhsum)。其中，翻译采用谷歌翻译。

尽管通过翻译构建跨语言摘要数据集是一种简便快捷的方法，但数据集的质量极大程度受到机器翻译性能的约束。对此，基于回译后的数据，采用 Rouge^[5]、BERTScore^[6] 与 MsfScore^[7]对回译数据进行数据过滤，在 Rouge 筛选中，计算 Rouge-1、Rouge-2、Rouge-L的平均值作为最终得分，而在 BERTScore 与 MgfScore 评估中则采用 F 值得分。以汉语-越南语跨语言摘要数据筛选为例，具体操作流程如图 1 所示。

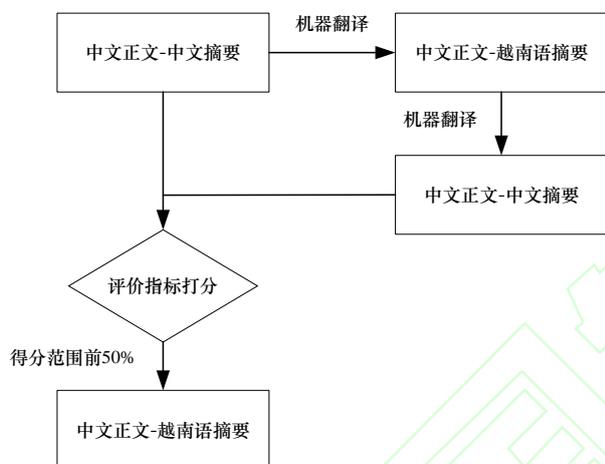


图 1 汉语-越南语数据筛选流程图

Fig.1 Chinese-Vietnamese data screening flow chart

其中，在 Zh-Visum 中，过滤掉得分最低 50% 的数据，留下 10 万条汉语-越南语跨语言摘要数据。而 Vi-Zhsum 的回译质量相对较高，过滤掉得分最低 30% 的数据，剩下 8.1 万条越南语-汉语跨语言摘要数据，数据集过滤前后回译得分详细信息，如表 1 所示。

表 1 各数据集回译得分表

Table 1 Back-translation score table for each data set

DATA	Zh-Visum				Vi-Zhsum			
	RG-1	RG-2	RG-L	BERTScore	RG-1	RG-2	RG-L	MgfScore
未过滤前得分	52.71	28.19	48.62	74.90	67.52	43.21	64.00	87.86
过滤后得分	65.70	41.10	61.34	81.18	73.55	50.89	70.86	90.36

2.2 数据分析

从上一节，可以看到对回译数据的过滤有效提升了汉语-越南语以及越南语-汉语两个跨语言摘要数据集的

质量，但进一步对汉越跨语言摘要进行分析，发现数据中完全正确的句子占比较小。而在训练模型中需要高质量、大规模的数据，因此，即使对数据进行过滤也只能去除那些低质量数据（错误严重），无法避免数据集中的弱噪声（错误不严重）。由此，本文进一步对机器翻译构造的跨语言数据进行噪声分析。根据文献^[21]中划分的类型进行统计，具体噪声类型如表 2 所示。值得注意的是，随着机器翻译系统性能的提升以及对本文噪声数据类型的分析，发现第 4 与第 6 类错误占比很小。所以在该数据的噪声类型结果统计中剔除了第 4 与第 6 类噪声。

表 2 CWMT2013 划分常见类型错误

Table 2 CWMT2013 division common type error

噪声类型	具体情况
1. 译文选词错误(选词不当)	对原文词语进行了翻译，但翻译后的词语错误或翻译不准确
2. 实词译文缺失(实词缺失)	没有翻译原文的实词或错误的照搬原文实词
3. 词序不对	译文语序错误
4. 译文与原文意思相反	译文中的词语或句子含义与原文完全相反
5. 命名实体问题	命名实体(人名、地名、机构名、组织名等)漏翻或翻译错误
6. 数量词/时间词问题	数量词或时间词翻译错误
7. 其它错误	不属于前 6 类错误中的其它错误
8. 没有错误	译文表达完整且正确

本文在汉语-越南语与越南语-汉语跨语言摘要数据集上各抽取 100 句标准源语言摘要与目标语言摘要句进行人工标记，对过滤前后的数据进行噪声类型统计，得到结果如表 3 所示。其中，Filter-No 表示未过滤，Filter-RG、Filter-Bert 和 Filter-Msf 则分别代表使用 Rouge、BERTScore 和 MgfScore 进行数据过滤；Zh-Visum 过滤 50% 数据，Vi-Zhsum 过滤 70% 数据。

表 3 汉越跨语言摘要数据集噪声类型占比情况

Table 3 The proportion of noise types in the Chinese-Vietnamese cross-language summarization dataset

噪声类型	Zh-Visum			Vi-Zhsum		
	Filter-No	Filter-RG	Filter-Bert	Filter-No	Filter-RG	Filter-Msf
1 选词不当	37.00%	30.67%	29.34%	28.25%	23.58%	22.38%
2 实词缺失	17.50%	18.67%	18.32%	12.75%	15.71%	15.95%
3. 词序不对	6.33%	5.66%	4.67%	17.42%	15.24%	16.19%
4 命名实体错误	12.67%	13.00%	14.67%	7.75%	8.57%	8.57%
5 其他	6.50%	8.00%	7.00%	4.83%	5.47%	4.05%
6 无错	20.00%	24.00%	26.00%	29.00%	31.43%	32.86%

从表 3 中，可以看出：

- (1) 在构造得到的跨语言摘要数据集中无错的句子

占比较小，即使通过评价指标过滤虽然能提高数据的正确率，但也无法避免噪声数据。这也是在提高数据集质量后，仍需要进一步进行噪声下跨语言摘要生成方法研究的原因。

(2) 针对未过滤时正确句子的占比，在 Vi-Zhsum 中明显高于 Zh-Visum。这是由于 Vi-Zhsum 是基于越南语新闻网站爬取的单语数据翻译得到的，虽然越南语新闻摘要数据长度大于 LCSTS 摘要数据，但新闻数据大多表达句式规整且通俗易懂，机器翻译在此类数据集上翻译表现更好。

(3) 针对 Zh-Visum 数据，可以看出噪声类型占比最大的是选词不当与实词缺失。使用 Rouge 与 BERTScore 数据筛选后，选词不当的占比下降较为明显。由此可见，在该数据集中部分属于选词不当类型的句子错误严重，这是因为 LCSTS 是在新浪微博上获取以标题作为摘要的短文本摘要数据集，此摘要中大多中文词语表达短小精悍，而机器翻译往往对此类文本理解容易出现偏差，翻译时还常忽略部分实词，所以在 Zh-Visum 中一半以上噪声均来自选词不当与实词缺失。相比在 Vi-Zhsum 中，词序不当错误占比较高。这是 Vi-Zhsum 是由较长的文本翻译而来，而机器翻译对于长文词语间逻辑顺序理解能力较弱，翻译时容易出现语序错误。

(4) 另外，使用评价指标筛选后命名实体识别错误类型占比增大。一方面，BERTScore 是一种基于子词的评价方法，基于词级的数据筛选方法对命名实体错误不敏感。另一方面，在本文数据集中，命名实体大部分为人名、地名，此类错误大部分按谐音翻译出现偏差。相对其他噪声类型，该类型给句子带来的噪声较弱。

根据上述分析，在汉语-越南语短文本和越南语-汉语长文本的跨语言摘要数据集中，噪声类型占比最大的都是选词不当与实词缺失。因此，对数据进行筛选以提高通过翻译生成的伪数据质量，并继续弱化噪声是非常必要的。

3 多策略强化学习的汉越跨语言摘要方法

针对汉越跨语言摘要中监督信号中存在的噪声问题，本文提出了一种多策略强化学习方法来改善汉越跨语言摘要生成。在 Transformer^[22]模型的基础上，该方法通过源语言摘要和目标语言生成摘要之间的词相关性和

词缺失度设置奖励来结合强化学习函数和最大似然估计函数作为训练目标，以此来提高生成摘要的质量并减少噪声对伪目标语言摘要的影响。模型结构如图 2 所示。

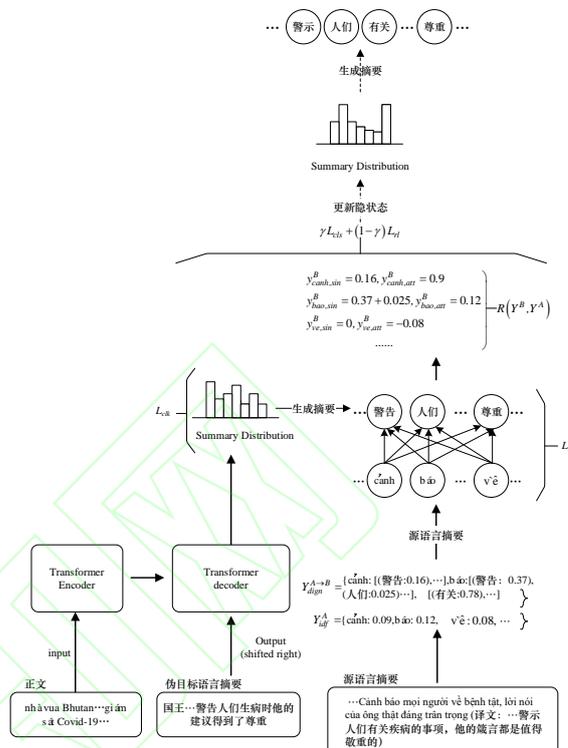


图 2 多策略强化学习的汉越跨语言摘要模型

Fig.2 A cross-lingual summary model for multi-strategy reinforcement learning of Chinese and Vietnamese

3.1 交叉熵损失

在基于 Transformer 架构的传统跨语言摘要模型中，给定训练集 $\{X^A, \tilde{Y}^B\}$ ， A 代表源语言， B 代表目标语言。对每个文档 X^A 进行高维向量映射得的输入文档序列 $X^A = \{x_1, x_2, x_3, L, x_N\}$ ，并输入编码器进行编码得到文档序列的向量表征 $H = \{h_1, h_2, h_3, \dots, h_N\}$ 。最后，解码器依据给定的 H 进行解码，解码器依次生成摘要序列 $Y^B = \{y_1, y_2, y_3, L, y_M\}$ 。在该过程中使用生成摘要 Y^B 与标准摘要 \tilde{Y}^B 间的最大似然估计作为优化目标，交叉熵损失函数定义为：

$$L_{clex} = - \sum_{t=1}^M \log P(y_t^B | y_{<t}^B, X^A) \quad (1)$$

其中 M 为 Y^B 摘要的长度。

3.2 强化学习策略

训练集 $\{X^A, \tilde{Y}^B\}$ 是由单语摘要数据集 $\{X^A, Y^A\}$ 翻

译得到的,在前文中探究了 \tilde{Y}^B 数据中占比较大的噪声类型为选词错误与实词缺失。对此,在本文中引入源语言摘要为基准,计算源语言摘要 Y^A 与生成目标语言摘要 Y^B 间的词相关性与词缺失度两个方面,设计强化学习奖励,弱化伪目标语言摘要作为监督信号带来的错误指导问题。

词相关性(Correlation)方面,使用源语言摘要序列 $Y^A = \{y_1^A, y_2^A, y_3^A, \dots, y_L^A\}$ 直接评估目标语言生成摘要词汇的质量 $Y^B = \{y_1^B, y_2^B, y_3^B, \dots, y_M^B\}$ 。预先使用fast-align^[23]工具对中-越双语平行语料对齐,得到每个源语言词汇与目标语言词汇间的相关度表示,记为 $Y_{align}^{A \rightarrow B}$ 。如公式(2)所示,使用 t 时刻生成的目标语言摘要词汇 y_t^B ,与 $Y_{align}^{A \rightarrow B}$ 中的每个源语言摘要词汇 Y^A 匹配,记为 $y_{j,sim}^B$,即 Y^B 与每个源语言摘要词汇 y_j^A 的相关度值,具体操作如图2中间部分。

$$y_{j,sim}^B = sim(y_t^B (Y_{align}^{A \rightarrow B})^T)_{sum} \quad (2)$$

其中, sim 为相关性计算,在本文中,我们使用fast-align工具对汉语-越南语进行双语对齐,并计算两种语言之间词汇的相关性; sum 表示取和。

在词缺失度(Missing Degree)方面,计算源语言摘要 $Y^A = \{y_1^A, y_2^A, y_3^A, \dots, y_L^A\}$ 中每个词汇重要程度,记为 Y_{idf}^A 。也可使用该词在上下文中的重要程度来匹配生成摘要词汇的重要程度或词缺失程度。如公式(3)所示,在词相关性中,如 t 时刻生成的目标语言摘要词汇 y_t^B 能匹配到对应源语言摘要序列 Y^A 中的词汇时,则将源语言摘要中所匹配到词语的重要程度记为生成摘要的 $y_{j,att}^B$ 的重要程度;当 t 时刻生成摘要 y_t^B 匹配不到 Y^A 中词汇时,则认为生成摘要中该词缺失,此时将 Y^A 中未匹配到词的重要程度记为生成摘要中的词缺失度 $y_{j,att}^B$,以此来避免伪目标语言中重要词缺失对模型学习造成的影响。

$$y_{j,att}^B = \begin{cases} y_{j,idf}^A, y_{j,sim}^B > 0 \\ -y_{j,idf}^A, y_{j,sim}^B = 0 \end{cases} \quad (3)$$

其中,使用TF-IDF计算词汇重要程度。

在跨语言摘要模型中,可以将跨语言摘要模型看作一个智能体(Agent),每个解码 t 时刻得到的上下文表征向量以及前 $t-1$ 时刻生成的摘要 $y_{<t}^B$ 可以看做智能体

中环境(Environment),从候选词表中选取哪一个词作为解码 t 时刻生成的摘要词 y_t^B ,即为智能体的一个动作(Action),而选择哪一个词是依据策略(Policy)产生的,即概率分布函数。当智能体生成摘要时,模型就会得到一个奖励(Reward),记为 $R(Y^B, Y^A)$ 。在本文中采用公式(4)计算期望奖励。其中,使用生成摘要中每个词汇与目标语言中对应词汇的相关度和缺失度来评估当前生成摘要的质量,以此来避免伪目标语言摘要中的噪声带来的错误指导。

$$R(Y^B, Y^A) = \frac{1}{L} \sum_{j=1}^L \begin{cases} (y_{j,sim}^B y_{j,att}^B), y_{j,sim}^B > 0 \\ \sum_{j=1}^L y_{j,sim}^B \\ \text{Count}(y_{j,sim}^B > 0) y_{j,att}^B, y_{j,sim}^B = 0 \end{cases} \quad (4)$$

其中 L 表示源语言摘要的长度, $\text{Count}(y_{j,sim}^B > 0)$ 表示 $y_{j,sim}^B > 0$ 的次数。

在强化学习的训练过程中,其目标是最大化期望奖励,在强化学习损失中定义为:

$$L_{rl} = - \sum_{Y^B \in Y} \log P(Y^B | X^A, \theta) R(Y^B, Y^A) \quad (5)$$

其中 Y 代表所有可能生成的候选摘要,这是一个指数级别的搜索空间。在实际操作中,常从概率分布函数 $P(Y^B | X^A, \theta)$ 中采样一个序列 Y^S 来优化上述期望奖励,但由此也带来了期望奖励而存在较高的方差。此时,引入一个基线奖励来减小梯度方差,为了解决该问题采取与前人^[24-25]相同的方法。在强化学习的目标训练中,使用自我批判策略梯度训练(self-critical policy gradient training)算法,训练时采用两个策略生成摘要:依据条件概率函数 $P(Y^B | X^A, \theta)$ 从中随机采样得到 Y^S ;贪婪解码得到 Y^G 。由此,一个摘要句的强化学习的训练目标为:

$$L_{rl} = - \left(R(Y^S, Y^A) - R(Y^G, Y^A) \right) \sum_{t=1}^M \log P(y_t^S | y_{<t}^S, X^A) \quad (6)$$

最后,我们采用线性插值的方式混合交叉熵损失函数和强化学习训练目标函数,得到跨语言摘要模型的混合训练目标函数,具体公式如下式(7)所示:

$$L_{mix} = \gamma L_{cls} + (1 - \gamma) L_{rl} \quad (7)$$

其中, γ 表示交叉熵损失函数与强化学习训练目标函数在混合目标函数中的比例因子。

4 实验

4.1 数据集

为了验证本文所提出模型的有效性,采用 2.1 的方法构造的 20 万 Zh-Visum 与 11.5798 万 Vi-Zhsum 进行基础试验。进行数据筛选后,得到一个包括 10 万样本的汉语-越南语跨语言摘要数据集 (Zh-Visum) 和一个 8.1 万样本的越南语-汉语跨语言摘要数据集。基于此,对数据集进行划分,详细数据如表 4 所示。划分方式采用不同的过滤方式对汉语-越南语跨语言摘要数据集和越南语-汉语跨语言摘要数据集进行处理,其中,使用 BERTScore 过滤汉语-越南语跨语言摘要数据集并表示为 Bert,使用 MgfScore 过滤越南语-汉语跨语言摘要数据集并表示为 Mgf,使用 Rouge 指标过滤的数据集表示为 RG。在本文中,为了公平比较,同一语种下的测试集保持不变。

表 4 实验数据详细信息
Table 4 Experimental data details

DATA	Zh-Visum(Filter)			Vi-Zhsum(Filter)		
	训练集	验证集	测试集	训练集	验证集	测试集
样本数	97000	3000	3000	77000	2000	2000
正文平均长度 -Bert/Mgf	90.05	92.18	89.45	445.87	511.39	426.95
摘要平均长度 -Bert/Mgf	14.59	13.13	17.33	40.60	41.99	40.13
正文平均长度-RG	89.92	92.17	89.45	446.93	516.23	426.95
摘要平均长度-RG	14.59	13.06	17.33	41.22	42.07	40.13

其中,在本实验中未说明的地方,Zh-Visum(Filter)数据集为基于 BERTScore 指标过滤的数据;Vi-Zhsum(Filter)数据集为使用基于 MgfScore 指标过滤的数据。

4.2 评价标准

在本文中,采用了两个评价指标来测评跨语言摘要系统生成摘要的质量。与大多数摘要工作相同,一种是基于统计的方法 Rouge^[5],计算标准摘要与生成摘要间的 N-gram 共现程度,计算公式如公式(8)所示:

$$ROUGE-N = \frac{\sum_{G \in \{Ref\}} \sum_{N-gram \in G} Count_{match}(N-gram)}{\sum_{G \in \{Ref\}} \sum_{N-gram \in G} Count(N-gram)} \quad (8)$$

其中, G 为生成摘要, Ref 为标准参考摘要, $N-gram$ 为 N 元词组, $Count_{match}(N-gram)$ 为生成摘要与标准摘要中的 N 元词组重叠个数, $Count(N-gram)$ 为标准摘要中 N 元词组个数。其中 N

常设置为 1, 2, L (最长公共子序列),在本文中使用 Rouge-1、Rouge-2、Rouge- L 评价生成摘要的质量,下表中为 RG-1、RG-2、RG- L 。

另一种 Zhang 等人^[6]近年提出基于深度语义匹配的评价方法 BERTScore,使用预训练语言模型计算生成句与参考句间的语义相似度,现今此方法也被不少学者广泛用于评价生成摘要的质量。在中文中,预训练模型使用“bert-base-chinese”计算得分;在越南语中,预训练模型使用“bert-base-multilingual-cased”。其中,使用 BERTScore 计算时,生成摘要中的“<unk>”替换为 BERT 词表中的“[UNK]”。

4.3 实验设置

本文中,采用 PyTorch 框架实现模型代码。在模型结构上,使用多层 Transformer 编码器和解码器结构,每层都采用 8 个多头注意力机制,隐层向量维度设置为 512,前馈神经网络设置为 1024。采用 Adam 作为模型优化器,参数 $\beta_1 = 0.9$, $\beta_2 = 0.98$, $\epsilon = 10^{-9}$ 。使用 teach-forcing 策略,平滑因子 (Label smoothing) 设置为 0.1, dropout 设置为 0.1。模型解码时,采用束搜索策略 (Beam search), beam size 设置为 5。值得注意的是,与 Wu 等人相同^[26-27],对带强化学习策略的模型,本文均使用未过滤的 Zh-Visum 与 Vi-Zhsum 数据进行参数初始化,然后使用过滤后的数据继续训练模型。

4.4 基准模型

为了验证多策略强化学习的汉越跨语言摘要方法的有效性,本文在 Zh-Visum(Filter)与 Vi-Zhsum(Filter)数据集上对以下基线模型训练并进行比较。

Sum-Tra: 是一种传统的跨语言摘要方法,先进行对输入的源语言文本进行自动摘要生成,对生成的摘要再进行翻译得到目标语言摘要。

Tra-Sum: 与 Sum-Tra 类似,是一种两步式的跨语言摘要方法,首先进行源语言文档到目标语言文档的翻译,在将目标语言文档输入自动摘要模型,得到目标语言摘要。在 Sum-Tra 与 Tra-Sum 中,本文中采用谷歌作为机器翻译模型,摘要模型采用无监督的抽取式方法 LexRank。

NCLS^[2]: 一种基于 Transformer 框架的端到端神经

网络的跨语言摘要模型。

LR-Rouge: 与本文提出的方法类似, 但使用 Rouge-L 得分计算奖励期望。

LR-MC: 本文提出的跨语言摘要模型, 交叉熵与强化学习结合作为优化目标, 其中, 期望奖励根据源语言摘要与生成目标语言摘要间的词缺失度与词相关性计算得到。

4.5 实验结果与分析

本文从不同角度设计实验, 验证汉越跨语言摘要基于多策略强化学习方法在噪声数据下的有效性。首先, 对比了本文提出的不同策略的强化学习方法与基线模型的效果; 紧接着, 探究基于强化学习设计的词相关性奖励与词缺失度惩罚对噪声下的模型有什么样的提升, 各部分对模型影响有多大; 其次, 研究了交叉熵损失函数和强化学习训练目标函数之间的比例因子对模型性能的影响; 接下来, 分别使用噪声过滤前后的数据训练模型, 探究神经网络模型在不同数据下的表现; 最后, 针对不同模型生成的摘要进行了实例分析。

(1) 与基线模型对比结果

本节所提出的模型与基线对比结果如下表 5 所示。其中 γ 为交叉熵损失与奖励期望间比例因子, $\gamma=1$ 时, 即不加入强化学习奖励。

表 5 基线实验对比结果

Table 5 Baseline experimental comparison results

Model	Zh-Visum(Filter)				Vi-Zhsum(Filter)			
	RG-1	RG-2	RG-L	BERT Score	RG-1	RG-2	RG-L	BERT Score
Sum-Tra	17.78	8.13	16.54	63.29	19.65	6.76	15.70	60.59
Tra-Sum	20.92	10.24	18.97	65.36	22.61	8.24	16.89	61.61
NCLS	22.69	10.26	20.96	66.66	22.45	8.88	18.87	62.87
LR-Rouge	23.16	10.83	21.36	66.79	22.63	9.30	19.31	62.82
LR-MC ($\gamma=1$)	22.81	10.49	20.87	66.71	22.66	9.14	19.21	62.66
LR-MC ($\gamma=0.6$)	23.40	10.93	21.60	66.91	23.29	9.32	19.57	62.87

从表 5 可以看出, 本文提出的多策略强化学习跨语言摘要方法与基线模型相比在汉语-越南语和越南语-汉语跨语言摘要数据集上性能均取得了提升, 其中, 与端到端的跨语言摘要模型 NCLS 基准模型相比, 本文提出的方法在汉语-越南语跨语言摘要数据集上 RG-1、RG-2、RG-L 分别提升了 0.71、0.67、0.64 个点; 在越南语-汉语跨语言摘要数据集上 RG-1、RG-2、RG-L 分别提升了

0.84、0.44、0.7 个点。表明本文方法与传统的端到端模型相比能够有效弱化汉越跨语言摘要数据中噪声的干扰, 提升跨语言摘要模型性能。与利用 Rouge-L 作为强化奖励的 LR-Rouge 方法相比, 本文方法在 RG-1、RG-2、RG-L 和 BERTScore 上均取得了提升, 说明利用源语言摘要与生成摘要的单词相关性和单词缺失度来设计强化学习奖励能够更好地减弱汉越跨语言摘要数据中噪声的干扰, 从而提升跨语言摘要模型的性能。使用噪声数据训练后的模型, 在真实的数据上进行继续训练, 模型性能也能得到进一步的提升, 相较而言 RG-2 的提升较大, 这是由于真实的数据中伪摘要文本质量更高、句子连贯性更好, 所以生成的摘要较之前得到了进一步提升。相比于直接使用交叉熵损失函数优化模型时, 加入本文提出的多策略奖励期望能有效弱化噪声。其中, 在 Zh-Visum 数据下 RG-1 (0.59 \uparrow)、RG-2 (0.44 \uparrow)、RG-L (0.73 \uparrow)、BERTScore (0.20 \uparrow); 在 Vi-Zhsum 数据下 RG-1 (0.62 \uparrow)、RG-2 (0.18 \uparrow)、RG-L (0.36 \uparrow)、BERTScore (0.21 \uparrow)。使用真实的源语言摘要计算奖励期望, 相比与 RG-L 计算奖励期望与交叉熵损失函数混合来优化模型性能有进一步的提升, 说明本文提出的多策略强化学习方法无论是在汉语-越南语跨语言摘要数据集或是越南语-汉语跨语言摘要数据集下都有较好的表现, 同时在噪声数据下的短文本和长文本摘要任务中也表现出了较好的性能, 能在一定程度上弱化伪目标语言摘要中噪声带来的影响。

(2) 消融实验

为了验证本节中提出的基于词相关性与词缺失度的强化学习奖励对模型性能的影响, 采用各单一模块进行试验, 结果如表 6 所示。其中, LRmis 为只计算生成摘要缺失度作为期望奖励, LRcor 为只计算生成摘要相关性作为期望奖励, γ 均为 0.6。

表 6 消融实验结果

Table 6 Results of ablation experiments

Model	Zh-Visum(Filter)				Vi-Zhsum(Filter)			
	RG-1	RG-2	RG-L	BERT Score	RG-1	RG-2	RG-L	BERT Score
LRmis	22.78	10.67	21.02	66.73	22.50	9.13	19.18	62.74
LRcor	23.15	10.85	21.38	66.76	22.83	9.23	19.28	62.83
LR-MC	23.40	10.93	21.60	66.91	23.28	9.32	19.57	62.87

从表 6 可以看出, 只计算源语言真实与目标语言生成摘要间的缺失度计算奖励期望时(LRmis), 性能下降较

为明显。仅使用相关性计算奖励时(LRcor)下降较小。我们认为这是由两方面造成的,一方面,只使用缺失度时,模型得到的信息较为单一;另一方面,缺失度只针对实词缺失这一噪声类型设计的,从2.2节中噪声数据的分析中,可以得知实词缺失占比小于选词不当。

(3) γ 参数实验,实验结果如表7所示

表7 γ 参数实验结果

Table7 γ parameter experiment result

γ	Zh-Visum(Filter)				Vi-Zhsum(Filter)			
	RG-1	RG-2	RG-L	BERTScore	RG-1	RG-2	RG-L	BERTScore
1	22.81	10.49	20.87	66.71	22.66	9.14	19.21	62.66
0.8	23.22	10.83	21.37	66.75	22.81	9.23	19.35	62.97
0.6	23.40	10.93	21.60	66.91	23.28	9.32	19.57	62.87
0.4	23.20	10.95	21.35	66.71	22.55	9.14	19.20	62.78
0.2	22.91	10.69	21.07	66.58	22.16	8.90	18.93	62.42

从表7中,可以看出奖励期望与交叉熵损失函数结合参数 γ 为0.6左右模型性能最好。当 γ 值较大($\gamma=1$)时,即不加入强化学习奖励时,模型在所有指标上的性能较低,表明强化学习奖励对模型的性能有积极的影响。随着 γ 的减少,即奖励期望的比例的增加,模型性能并没有发挥到最优。结合实验结果对解码的测试集数据观察,发现奖励期望的比例增加时,解码得到的未登录词占比增大,这是造成生成摘要质量下降的主要原因。我们认为使用强化学习奖励作为优化目标函数,基于源语言的词级奖励中更多包含词级信息,并不包含目标语言的词语间的逻辑关系与语序特征。相比与短文本汉-越跨语言摘要在长文本越-汉跨语言摘要中,长文中的词序以及词语间的逻辑关系属性关系占比更大。这也是在越-汉跨语言摘要中增加奖励期望的比例时,模型性能下降更快的原因。因此,即使本文设计的基于源语言的词级奖励对噪声有很好的弱化作用,但不建议使用该奖励期望单独使用来训练模型。使用奖励期望与交叉熵损失相结合使用,在弱化噪声的同时也可以更好的学习到目标语言词语间的语序信息,进一步提升汉越跨语言摘要模型性能。

(4) 探究噪声数据对模型性能的影响

为了充分探究噪声数据对神经网络模型的影响,在本实验中,使用基础的Transformer框架进行噪声数据对比实验,结果详见表8。All表示使用20万未过滤的汉语-越南语跨语言摘要数据和11.5798万未过滤的越南语-汉语跨语言摘要数据进行训练;Filter-Bert/Mgf表示训练

数据采用过滤后的数据进行训练,其中汉语-越南语跨语言摘要数据集使用BERTScore方式进行过滤,越南语-汉语跨语言摘要数据集使用Mgfscore方式进行过滤,数据集详细信息可见表4;Random表示从未过滤数据集中随机抽取相同数量的数据进行训练。

表8 不同数据下的实验结果

Table 8 Experimental results under different data

Data	Zh-Visum				Vi-Zhsum			
	RG-1	RG-2	RG-L	BERT Score	RG-1	RG-2	RG-L	BERT Score
All	21.77	9.98	20.09	66.37	22.26	9.00	19.03	62.56
Filter-Bert/Mgf	22.69	10.26	20.96	66.66	22.46	8.88	18.87	62.87
Filter-Rouge	22.64	10.19	20.89	66.56	22.37	8.79	18.87	62.63
Random	20.98	9.48	19.33	65.96	21.01	7.79	17.61	62.12

根据表8实验数据,神经网络模型对噪声数据较为敏感。因此,为了训练出更好的模型,需要过滤掉噪声数据。在汉语-越南语跨语言摘要数据集中,噪声数据的比例较高,经过筛选后使用前10万条高质量数据进行训练能够比使用20万未过滤数据训练的模型更有效地生成可读性高的摘要。相对而言,越南语-汉语跨语言摘要数据的总量相对较小,但质量相对较高,过滤掉前30%的数据训练模型在RG-2和RG-L指标上略逊于使用全部数据训练的模型。然而,不管在哪个数据集下,噪声都会对模型产生负面的影响。因此,必须从噪声数据出发对汉越跨语言摘要研究进行探索。

(5) 实例分析

表9以越-汉摘要任务为例,展示了不同的摘要模型生成的摘要示例。从表格9可以观察到,相较于其他几种摘要模型,本文提出的方法生成的摘要质量更高,语义更为连贯,且提供的信息更加完整,在内容上更加接近参考摘要。在未使用过滤的数据训练的基础模型(Transformer-all),生成的摘要信息较少。经过使用高质量数据进行继续训练模型后,各个模型都试图生成更加丰富的信息,然而,只有本文所提出的多策略强化学习汉越跨语言摘要模型才能生成关键的信息:“迄今为止越南已记录#名患者”。

表9 不同的汉越跨语言摘要模型生成的摘要示例

Table 9 Examples of summaries generated by different Chinese-Vietnamese cross-language summarization models

正文	2 ca cách ly ngay sau khi nhập cảnh tại An Giang. 76 ca ghi nhận trong nước tại TP. Trong đó 71 ca được phát hiện trong khu cách ly hoặc khu đã được phong tỏa. Việt Nam có tổng cộng 11.289 ca ghi nhận trong nước và
----	--

	1.689 ca nhập cảnh.Số lượng ca mắc mới tính từ ngày 27/4 đến nay: 9.719 ca, trong đó có 2.280 bệnh nhân đã được công bố khỏi bệnh..... (译文: 进入安江后立即隔离了2病例。胡志明市内记录76例, 其中71例已隔离或封锁。越南国内累计11289例, 境外输入1689例。4月27日至今新增病例: 9719例, 其中2280例已治愈.....)
标准摘要	卫生部6月20日上午发布的 covid-19 流行病公报说还有76例 covid-19 病例, 胡志明市仍然是最多的有46例, 迄今为止越南共记录了12978名患者。
Transformer-all	卫生部#月#日下午发布的 covid-19 流行病公报说还有#<unk>例 covid-19 病例, 其中胡志明市继续保持最多为<unk>例。
LR-Rouge	卫生部#月#日下午发布的 covid-19 流行病公报说还有#<unk>例 covid-19 病例, 其中胡志明市仍然是最多的, 是最多的有基础疾病。
LR-MC($\gamma=1$)	卫生部#月#日下午发布的 covid-19 流行病公报说还有#<unk>例 covid-19 病例, 其中胡志明市继续保持最多为<unk>例, 白天宣布治愈<unk>名患者。
LR-MC($\gamma=0.6$)	卫生部#月#日下午发布的 covid-19 流行病公报说还有#<unk>例 covid-19 病例, 其中胡志明市仍然是最多的有<unk>例, 迄今为止越南共记录了<unk>名患者。

5 总结

本文针对汉越跨语摘要中的噪声问题进行分析与研究, 并针对伪目标摘要中存在选词不当与实词缺失两种噪声类型, 提出一种多策略的跨语言摘要方法, 用于汉越跨语言摘要, 采用强化学习技术, 使用真实源语言摘要和伪目标语言摘要作为基准, 通过计算源语言摘要与生成摘要的相关性和缺失度, 来计算期望奖励, 弱化噪声干扰; 保留传统的伪目标语言与生成摘要间的交叉熵损失, 以学习目标语言间的词序关系; 通过将强化学习损失函数和交叉熵损失函数相结合, 优化模型训练目标, 改善了直接使用伪目标语言摘要训练模型时噪声数据对生成摘要质量的负面影响, 从而提高了生成摘要的质量。在未来的工作中, 我们计划探索将本文的方法扩展到其他数据集和任务, 例如针对机器翻译数据噪声问题, 利用本文方法来降低噪声数据对机器翻译模型性能的影响。

参考文献

- [1] Duan Xiangyu, Yin Mingming, Zhang Min, Chen Boxing, Luo Weihua, et al. Zero-shot cross-lingual abstractive sentence summarization through teaching generation and attention[C]//Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. 2019: 3162-3172.
- [2] Zhu Junnan, Wang Qian, Wang Yining, Zhou Yu, Zhang Jiajun, et al. NCLS: Neural cross-lingual summarization [C]//Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP).2019: 3054 - 3064
- [3] Zhang Boliang, Nagesh Ajay, Knight Kevin. Parallel Corpus Filtering via Pre-trained Language Models[C]//Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics 2020: 8545 - 8554
- [4] Dou Zi-Yi, Kumar Sachin, Tsvetkov Yulia. A Deep Reinforced Model for Zero-Shot Cross-Lingual Summarization with Bilingual Semantic Similarity Rewards [C]// Proceedings of the Fourth Workshop on Neural Generation and Translation. 2020:60-68
- [5] Lin Chin-Yew. Rouge: A package for automatic evaluation of summaries[C]//Text summarization branches out. 2004: 74-81.
- [6] Zhang Tianyi, Kishore Varsha, Wu Felix, Weinberger Kilian Q, Artzi Yoav. BERTScore: Evaluating Text Generation with BERT[C]//International Conference on Learning Representations. 2019.
- [7] 赖华,高玉梦,黄于欣,余正涛,张勇丙.基于多粒度特征的文本生成评价方法[J].中文信息学报,2022,36(3):45-53+63.
- [8] Lai H, Gao Y M, Huang Y X, Yu Z T, Zhang Y B. Text Generation Evaluation Method Based on Multi-Granularity Features [J]. Journal of Chinese Information Science, 2022, 36(3): 45-53.(in Chinese)
- [9] Leuski Anton, Lin Chin-Yew, Zhou Liang, Zhou Liang, Germann Ulrich, Och Franz Josef, Hovy Eduard. Cross-lingual C* ST* RD: English access to Hindi information[J]. ACM Transactions on Asian Language Information Processing (TALIP), 2003, 2(3): 245-269.
- [10] Lim Jung-Min, Kang In-Su, Lee Jong-Hyeok. Multi-Document Summarization Using Cross-Language Texts [C]//In Proceedings of the Fourth NTCIR Workshop on Research in Information Access Technologies Information Retrieval, Question Answering and Summarization (NTCIR). 2002.
- [10] Orăsan Constantin, Chiorean Oana Andreea. Evaluation of a cross-lingual Romanian-English multi-document summarizer [C]//Proceedings of the Sixth International

- Conference on Language Resources and Evaluation (LREC'08).2008
- [11] Ayana, Shen Shi-qi, Chen Yun, Yang Cheng, Liu Zhi-yuan, Sun Mao-song, et al. Zero-shot cross-lingual neural headline generation[J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2018, 26(12): 2319-2327.
- [12] Zhu J , Zhou Y , Zhang J , et al. Attend, Translate and Summarize: An Efficient Method for Neural Cross-Lingual Summarization[C]// Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. 2020.
- [13] Cao Yue, Liu Hui, Wan Xiaojun. Jointly learning to align and summarize for neural cross-lingual summarization [C]//Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. 2020: 6220-6231.
- [14] Bai Yu, Gao Yang, Huang Heyan. Cross-Lingual Abstractive Summarization with Limited Parallel Resources [C]// Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (Volume 1: Long Papers). 2021: 6910-6924.
- [15] Kumar G , Foster G , Cherry C , et al. Reinforcement Learning based Curriculum Optimization for Neural Machine Translation[C]// 2019.
- [16] Y You, Jia W , Liu T , et al. Improving Abstractive Document Summarization with Salient Information Modeling[C]// Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. 2019.
- [17] Paulus Romain, Xiong Caiming, Socher Richard. A Deep Reinforced Model for Abstractive Summarization[C]// International Conference on Learning Representations. 2018.
- [18] Böhmer F, Gao Y, Meyer C M, et al. Better Rewards Yield Better Summaries: Learning to Summarise Without References[J]. 2019.
- [19] Yoon Wonjin, Yeo Yoon Sun, Jeong Minbyul, Yi Bong-Jun, Kang Jaewoo. Learning by semantic similarity makes abstractive summarization better[J]. <https://arxiv.org/abs/2002.07767>, 2020.
- [20] Hu B, Chen Q, Zhu F. Lcsts: A large scale chinese short text summarization dataset[C]//Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing.2015: 1967 - 1972.
- [21] 赵红梅, 刘群. 机器翻译常见错误类型总结[J].第十届全国机器翻译研讨会.2013.
Zhao H M, Liu Q. Summary of Common Error Types in Ma-chine Translation[J]. Tenth National Machine Translation Sym-posium.2013.(in Chinese)
- [22] Vaswani Ashish, Shazeer Noam, Parmar Niki, Uszkoreit Jakob, Jones Llion, Gomez Aidan N, Kaiser L Ukasz, Polosukhin Illia. Attention is all you need[J]. Advances in neural information processing systems, 2017, 30: 5998-6008.
- [23] Dyer Chris, Chahuneau Victor, Smith Noah A. A Simple, Fast, and Effective Reparameterization of IBM Model 2 [C]//Proceedings of the 2013 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. 2013: 644-648.
- [24] Rennie Steven J., Marcheret Etienne, Mroueh Youssef, , Ross Jerret, Goel Vaibhava. Self-critical sequence training for image captioning[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 7008-7024.
- [25] Kang Xiaomian, Zhao Yang, Zhang Jiajun, Zong Chengqing. Dynamic Context Selection for Document-level Neural Machine Translation via Reinforcement Learning[C]// Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). 2020: 2242-2254.
- [26] Wu Lijun, Tian Fei, Qin Tao, Lai Jianhuang, Liu Tie-Yan. A Study of Reinforcement Learning for Neural Machine Translation[C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. 2018: 3612-3621.
- [27] Jauregi Unanue I., Parnell J., Piccardi M. BERTTune: Fine-Tuning Neural Machine Translation with BERTScore [C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (Volume 2: Short Papers). Association for Computational Linguistics, 2021.