

基于 ERNIE - BiGRU - Attention - CRF 的电子病历命名实体识别方法*

王正芳¹ 张军亮^{1,2} 李小倩¹ 于月¹ 陈慧贞¹

(¹ 新乡医学院卫生健康管理学院 新乡 453003 ² 新乡医学院卫生信息资源研究中心 新乡 453003)

[摘要] 目的/意义 改善中文电子病历命名实体识别模型的性能, 更好地开展医疗信息的组织和挖掘。方法/过程 构建 ERNIE - BiGRU - Attention - CRF 中文电子病历命名实体识别模型, 首先采用 ERNIE1.0 预训练模型生成具有语义特征的词向量, 然后利用 BiGRU 捕获全局语义特征与语法结构特征, 通过 Attention 机制进一步增强语义特征的捕获, 最后连接 CRF 解码层输出全局概率最大的标签序列。结果/结论 在公开的医疗文本数据集 CCKS2017 开展对比实验、消融实验, 利用生成的模型进行实例分析, 取得较好的识别效果。

[关键词] 命名实体识别; ERNIE; 双向门控循环神经网络; 注意力机制; 条件随机场

[中图分类号] R - 058 **[文献标识码]** A **[DOI]** 10.3969/j.issn.1673-6036.2024.05.013

Named Entity Recognition Method of Electronic Medical Records Based on ERNIE - BiGRU - Attention - CRF

WANG Zhengfang¹, ZHANG Junliang^{1,2}, LI Xiaoqian¹, YU Yue¹, CHEN Huizheng¹

¹School of Health Management, Xinxiang Medical University, Xinxiang 453003, China; ²Center for Health Information Resources, Xinxiang Medical University, Xinxiang 453003, China

[Abstract] **Purpose/Significance** To improve the performance of named entity recognition (NER) model of Chinese electronic medical records (EMR) for better organization and mining of medical information. **Method/Process** The ERNIE - BiGRU - Attention - CRF NER model of Chinese EMR is constructed. Firstly, the ERNIE1.0 pre-training model is used to generate word vectors with semantic features, and then BiGRU is utilized to capture the global semantic features and grammatical structural features, which are fed into the Attention mechanism to further enhance the capture of the semantic features, and finally, the CRF decoding layer is connected to output the label sequences with the maximum global probability. **Result/Conclusion** Comparison experiments and ablation experiments are carried out on the publicly available medical text dataset CCKS2017, and examples analysis is conducted using the generated model. The model proposed in this paper achieves better recognition results.

[Keywords] named entity recognition; ERNIE; bidirectional gated recurrent neural networks (BiGRU); attention mechanism; conditional random fields (CRF)

[修回日期] 2024 - 01 - 08

[作者简介] 王正芳, 硕士研究生, 发表论文 1 篇; 通信作者: 张军亮, 教授, 硕士生导师。

[基金项目] 国家社会科学基金项目 (项目编号: 21BTQ051); 新乡医学院研究生科研创新支持计划一般项目 (项目编号: YJSCX202285Y); 河南省高校哲学社会科学创新人才支持计划 (项目编号: 2023 - CXRC - 13)。

1 引言

命名实体识别 (named entity recognition, NER) 是知识挖掘的基础性工作之一, 能够识别出文本中具有特定意义的概念^[1], 支持知识图谱、问答系统等下游任务的开展, 是当前自然语言领域的研究热点^[2]。医学领域的 NER 用于提取医学文本资源中与疾病有关的语义概念实体, 为临床决策支持系统、循证医学和精准医学等提供数据支撑^[3]。电子病历是医疗大数据的重要资源之一, 既详细记录着患者诊疗的全过程, 也是医生知识与诊疗经验的重要体现, 有极高的挖掘价值^[4]。高效、准确地挖掘非结构化电子病历文本中有价值的实体, 对医疗信息化推广与普及以及医学知识发现与服务利用具有重要意义^[5]。

医疗领域的 NER 最早采用词典或规则模板构建方法, 如 IBM 基于病症信息词典构建的 Med-KAT^[6]、Mayo Clinic 参考统一医学语言系统^[7]术语词典构建的 cTAKES^[8]等。尽管基于字典和规则方法能够取得较高的准确率, 但新兴医学词汇不断涌现, 词典覆盖率低; 医生的书写习惯不一致, 规则模板难以统一; 专家参与所需的时间和人力成本高。学者将机器学习引入命名实体学习, 涌现出以支持向量机 (support vector machine, SVM)^[9]为代表的分类模型和以隐马尔可夫模型^[10]、条件随机场 (conditional random fields, CRF)^[11]等为代表的序列标注模型。整体来看, 由于 CRF 在一定程度上降低了人工构造成本, 被广泛应用, 但仍依赖于特征模板的构建质量。随着卷积神经网络^[12]和递归神经网络^[13]等神经网络在自然语言处理中的广泛运用, 结合词嵌入模式, 有效提高了 NER 效果。2018 年双向编码器表征 (bidirectional encoder representations from transformers, BERT)^[14]预训练模型的提出, 既解决了 Word2Vec^[15]、GloVe^[16]等静态词嵌入模型存在的一词多义问题, 也能通过微调更好地适应下

游任务, 为 NER 的发展提供了新思路。陈娜等^[17]在 CCKS19 数据集上采用 BERT、双向门控循环神经网络 (bidirectional gated recurrent units, BiGRU) 与 CRF 结合, 同时引入注意力 (Attention) 机制的方法, 识别效果 $F1$ 值为 84.11%; 梁怀众等^[18]提出基于医疗知识图谱的 BERT - BiLSTM - CRF 模型, 在现有公开数据集上识别效果优于既往模型。尽管采用 BERT 作为词嵌入, 能够取得较好效果, 但在掩码过程中, 仅仅基于字符级别, 忽略了中文字词间的语法结构及语义信息, 难以获得完整的语义理解与表示; 同时, 既往模型对全局特征信息的考虑较少, 有学者^[17, 19]考虑引入注意力机制, 优化效果。

鉴于此, 本文采用基于知识集成增强表示的预训练框架 (enhanced representation through knowledge integration, ERNIE)^[20]提高对中文文本的语义理解和表达能力, 采用双向门控循环神经网络提升模型效率, 同时, 引入注意力机制优化全局特征, 运用 CRF 实现序列标注, 提出基于 ERNIE - BiGRU - Attention - CRF 模型的中文电子病历 NER 方法。在 CCKS2017 数据集上进行对比实验、消融实验等验证。最后利用真实数据进行实例分析, 取得较好的实验效果。

2 模型结构

本文提出的 NER 模型主要由 4 部分组成: ERNIE 预训练模型、BiGRU 层、Attention 层和 CRF 层, 主要结构, 见图 1。首先, 通过 ERNIE 嵌入层对输入文本预训练, 生成动态词向量, 解决一词多义问题; 其次, 将词向量输入 BiGRU 层进行双向训练, 捕获上下文信息和更深层次的特征; 再次, 将特征向量输入 Attention 层, 增强关键语义特征的权重, 提升模型局部特征提取效果; 最后, 将权重分配之后的向量传入 CRF 层进行序列标注的约束, 输出全局最优序列标注结果, 完成 NER 任务。

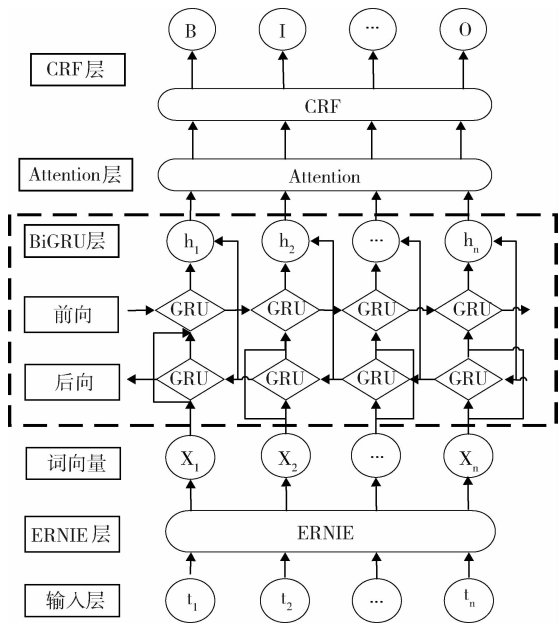


图 1 整体模型结构

2.1 ERNIE 模型

ERNIE 是对 BERT 模型的优化，既保留了 Transformer 架构，能理解动态语义，也优化了掩码 (mask) 策略，见图 2。第 1 阶段基本掩码策略与 BERT 一样，随机对文本中的字掩码，但此阶段难以充分学习到文本中高层次的语义知识；第 2 阶段词语级别的掩码策略，随机选择句子中的词语进行掩码与预测，此阶段词向量可以充分学习相关词语信息；第 3 阶段实体级别的掩码，随机选择句子中的实体进行掩码。经过 3 级掩码学习，ERNIE 模型能充分利用语料中字与词、实体间隐含的语法结构和语义信息，增强词向量对中文文本的语义表示能力，提升模型对全局语义关系的学习能力。此外，模型自身选用多种异质训练语料，鲁棒性和学习能力更强。

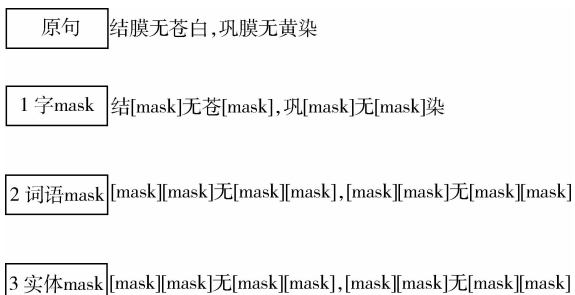


图 2 ERNIE 模型的 mask 策略

2.2 BiGRU 模型

神经网络模型凭借循环反馈的结构特点被广泛应用于解决文本序列问题，但是随着文本序列与词间距增加，节点间传递的信息与依赖逐渐下降。为了解决反向传播过程中出现的梯度爆炸与消失的问题，涌现出了大量的变体结构，如门控循环单元 (gated recurrent unit, GRU)^[21]、长短期记忆神经网络 (long short-term memory, LSTM) 等。二者都是通过门控机制控制信息流动，但 GRU 较 LSTM 结构参数更少，训练效率更高。GRU 的主要结构包含进行信息筛选和存储的更新门和对前一状态选择性遗忘的重置门，见图 3。

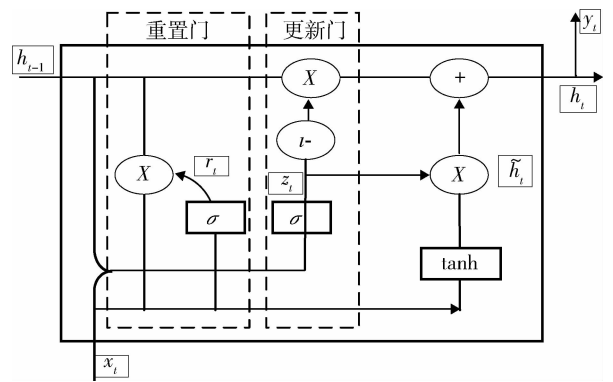


图 3 GRU 网络结构

GRU 网络的参数更新计算方法如下。其中， z_t 为更新门， r_t 为重置门， x_t 为 t 时刻文本序列输入字向量， h_t 为 t 时刻隐含层状态， h_{t-1} 表示 $t-1$ 时刻 (即前一刻) 隐含层输出状态， \tilde{h}_t 为 t 时刻候选隐藏状态， σ 为激活函数， W_z 、 W_r 、 W 为权重矩阵， \tanh 为双正切激活函数， \times 表示相乘， $+$ 表示加法。

$$z_t = \sigma(W_z \times [h_{t-1}, x_t]) \quad (1)$$

$$r_t = \sigma(W_r \times [h_{t-1}, x_t]) \quad (2)$$

$$\tilde{h}_t = \tanh(W \times [r_t \times h_{t-1}, x_t]) \quad (3)$$

$$h_t = R_{GRU}(h_{t-1}, x_t) = (1 - z_t) \times h_{t-1} + z_t \times \tilde{h}_t \quad (4)$$

在序列标注任务中，上下文内容对整个研究极为重要。因此，选取 BiGRU 捕获上下文特征信息，其计算过程如下。其中， \vec{h}_t 为前向 GRU 隐藏层输出， \overleftarrow{h}_t 为后向 GRU 隐藏层输出， h_t 为当前时刻隐藏层的双向输出状态，即前向 GRU 隐藏层输出与后

向 GRU 隐藏层输出的二者拼接。

$$\vec{h}_i = \overrightarrow{\text{GRU}}(x_i, \vec{h}_{i-1}) \quad (5)$$

$$\overleftarrow{h}_i = \overleftarrow{\text{GRU}}(x_i, \overleftarrow{h}_{i-1}) \quad (6)$$

$$h_i = \text{concat}(\vec{h}_i, \overleftarrow{h}_i) \quad (7)$$

2.3 Attention 层

注意力机制能够根据与电子病历实体的关联程度来赋予不同的权重，便于模型更好地学习电子病历实体的关键特征，进而优化模型的识别效果。因此，引入 Attention 层对 BiGRU 层输出的特征向量进行权重分配。计算方式如下。其中， u_x 表示隐藏层输出 h_x 经过全连接层生成的注意力权重向量， w_x 为权重矩阵， b_x 为偏置项， \tanh 为激活函数， n 为文本序列的长度， a_x 是经过 softmax 归一化处理后得到的注意力分数向量， q_x 为最终经过注意力机制权重分配后的加权全局语义特征向量。

$$u_x = \tanh(w_x h_x + b_x) \quad (8)$$

$$a_x = \text{softmax}(u_x) = \frac{\exp(u_x)}{\sum_{x=1}^n \exp(u_x)} \quad (9)$$

$$q_x = \sum_{x=1}^n a_x h_x \quad (10)$$

2.4 CRF 模型

CRF 是在输入一组给定的随机变量条件下输出另一组随机变量的条件概率分布模型^[22]，能够结合上下文关系与 BiGRU - Attention 输出的每个标签的具体分值，约束标签间的位置关系，如“1”标签只会出现在“B”标签之后，“B”标签不能与“B”标签相连等，借助维特比算法获取全局最优标注序列。CRF 模型计算过程：BiGRU - Attention 输出得分矩阵为 v ，大小为 $n \times k$ （词数 \times 标签数）， v_{ij} 表示文本序列中第 i 个字的第 j 个标签的分数。首先计算文本序列 $T = \{t_1, t_2 \dots t_n\}$ 的预测标签序列 $Y = \{y_1, y_2 \dots y_n\}$ 得分。其中， A 为转移分数矩阵， A_{ij} 表示标签 i 转移标签 j 的分数。

$$\text{score}(T, Y) = \sum_{i=0}^n A_{y_i, y_{i+1}} + \sum_{i=1}^n v_{i, y_i} \quad (11)$$

其次，利用归一化计算输出标签序列 Y 的概率。其中， \tilde{y} 表示真实的标注序列， y_i 表示所有可能

的标注序列。最后，采用维特比算法得到全局最优标签序列。

$$p(y | t) = \frac{\exp(\text{score}(t, y))}{\sum_{\tilde{y} \in \mathcal{Y}_t} \exp(\text{score}(t, \tilde{y}))} \quad (12)$$

3 实验设计与结果分析

3.1 实验数据

实验选取 CCKS2017 数据集^[23]，该数据集标注了疾病和诊断、治疗、身体部位、症状和体征、检查和检验 5 类医疗实体，按照 7:3 划分为训练集和测试集，见表 1。

表 1 CCKS2017 数据集实体类型及数量统计

实体类别	训练样本量 (个)	测试样本量 (个)	合计 (个)
疾病和诊断	487	235	722
治疗	774	274	1 048
身体部位	7 312	3 407	10 719
症状和体征	5 391	2 440	7 831
检查和检验	6 594	2 952	9 546
合计	20 558	9 308	29 866

3.2 实验环境与参数

本文实验环境配置：操作系统为 Ubuntu 20，深度学习框架为 PyTorch，GPU 为 NVIDIA GeForce RTX 4090。模型参数设置：ERNIE 模型为 12 头模式，隐藏层维度为 768，最大序列长度为 512；BiGRU 隐藏层维度为 768；BiLSTM 隐藏层维度为 768；学习率为 $1e - 4$ ；优化器为 Adam，随机失活 (Droupout) 为 0.3。

3.3 模型评价指标

采用精准率 P (precision)，召回率 R (recall) 和 F1 值 (F1 - Score) 3 项指标评估模型识别效果。各指标计算公式如下。其中， T_p 表示成功识别的正确实体个数，即预测为正，实际为正； F_p 表示未成功识别的正确实体个数，即预测为正，实际为负； F_N 表示语料库中存在但未被识别的实体数，即预测为负，实际为正。

$$P = \frac{T_p}{T_p + F_p} \times 100\% \quad (13)$$

$$R = \frac{T_p}{T_p + F_n} \times 100\% \quad (14)$$

$$F1 = \frac{2PR}{P + R} \times 100\% \quad (15)$$

3.4 实验设计

3.4.1 不同标注方式对比 采用模型验证 BIO 和 BIOES 不同数据标注方式的性能。BIO 实体标注规则中，B 代表实体头部，I 代表实体中间或尾部，O 代表非实体；BIOES 标注规则中，B 代表实体头部，I 代表实体中间位置，E 代表实体尾部，S 代表单个字符的实体，O 代表非实体。BIOES 标注法的 F1 值较 BIO 标注法高 0.25 个百分点，细致化的标注方式既能详尽反映其位置信息，也能带来更好的识别效果，见图 4。因此，后续皆采用 BIOES 标注方式。




图 4 不同标注方式的实验结果

3.4.2 不同模型性能对比 为了更好地展示本文提出的模型在中文医疗电子病历中的识别效果，选取以下主流模型开展对比实验，见表 2。(1) 融合多特征的双通道神经网络 (dual channel neural network, DCNN) 模型。廖涛等^[24]设计融合多特征的双通道神经网络模型，将词嵌入送入 DCNN 进行特征提取，差异融合多特征，引入注意力机制进行特征程度区分，CRF 进行最后解码。(2) Lattice - BiGRU - CRF。陈嵩^[25]提出以基于字符方法的 BiGRU 为主干网络，利用晶格 (Lattice) 结构将词与字符相连接，经过 CRF 层获得最优序列。(3) BiLSTM - CRF - SP + ELMo。罗凌等^[26]面向生物学领域训练得到包含汉字内部结构信息与上下文结构信息的中文笔画 ELMo 模型，结合私有共享多任务学习框架改善模型识别性能。(4) LM - Att - BiGRU - CRF。唐国强等^[27]首先训练得到双向语言模型和字嵌入向量表示，然后分别送到 BiGRU 和预训练语言模型进行训练与拼接，将拼接向量送入另一个 BiGRU 和多头注意力模块开展特征提取，最后连接 CRF 模块。(5) RoBERTa - wwm - MLDF - CRF。林令德等^[28]采用中文 RoBERTa - wwm 预训练模型获得各层隐状态序列，利用多层动态融合 (multi-layer dynamic fusion, MLDF) 捕获语义信息，CRF 获取最优输出序列。

表 2 不同 NER 模型对比实验结果

序号	模型	标注方式	指标 (%)		
			P	R	F1
1	融合多特征的双通道神经网络模型 ^[24]	BIO	90.14	87.29	88.69
2	Lattice - BiGRU - CRF ^[25]	BIO	90.40	91.70	91
3	BiLSTM - CRF - SP + ELMo ^[26]	—	—	—	91.75
4	LM - Att - BiGRU - CRF ^[27]	BIESO	90.83	91.64	91.24
5	RoBERTa - wwm - MLDF - CRF ^[28]	BIESO	92.60	91.90	92.24
6	ERNIE - BiGRU - Attention - CRF (本文方法)	BIESO	91.45	93.48	92.46

模型 1、模型 2、模型 3 均增加了特征工程，取得较好的识别效果，侧面反映特征工程能够优化实体识别效果；相较于其他 4 种主流模型，模型 5 在不增加特征工程的基础上取得最好的识别效果，进

一步说明预训练模型的识别效果优于特征工程。从整体上看，本文提出的不增加特征工程的 ERNIE - BiGRU - Attention - CRF 模型的 F1 高于其他 5 种模型，该模型具有较好的识别性能。

3.4.3 消融实验 为验证 ERNIE - BiGRU - Attention - CRF 模型各部分的有效性,设计消融实验。选取 BERT - BiLSTM - CRF 作为基线模型,设置多组对照实验,探究不同预训练模型、不同特征提取

层对实体识别效果的影响。基线预训练模型选用谷歌发布的中文 BERT 模型,在糖尿病语料数据集上微调;ERNIE 选用百度实验室发布的 1.0 版本。实验结果,见表 3。

表 3 消融实验结果

序号	模型	训练时间 (s)	指标 (%)		
			P	R	F1
1	BERT - BiLSTM - CRF	294.658 3	91.13	92.31	91.72
2	ERNIE - BiLSTM - CRF	295.040 9	90.73	93.35	92.02
3	ERNIE - BiLSTM - Attention - CRF	327.202 8	91.10	93.43	92.25
4	ERNIE - BiGRU - CRF	280.147 8	91.11	93.22	92.15
5	ERNIE - BiGRU - Attention - CRF	310.136 3	91.45	93.48	92.46

对比模型 1 和模型 2 的指标值,ERNIE 模型在实体识别方面的 F1 值高于 BERT 模型 0.3 个百分点,表明 ERNIE 预训练模型优于 BERT 预训练模型,能够提高模型的识别效果。对比模型 1 与模型 2、模型 2 与模型 4、模型 3 与模型 5 的训练效果,可以看出含有 BiGRU 的模型识别效果优于含有 BiLSTM 的模型,且识别时间更短,表明 BiGRU 在保证识别效果的基础上,缩短了训练时间。对比模型 2 与模型 3、模型 4 与模型 5,可以看出加入注意力机制后模型的实体识别能力分别提高 0.23 个百分点和 0.31 个百分点,反映出注意力机制优化了模型语义特征提取能力,提升了实体识别性能。

3.4.4 模型性能及错误分析 为了更好地展现本文提出的模型在各类实体上的识别效果,详细统计了 CCKS2017 数据集各实体的 P、R、F1 值,见表 4。

表 4 ERNIE - BiGRU - Attention - CRF 模型不同实体的识别效果 (%)

实体类别	P	R	F1
身体部位	87.10	89.55	88.31
检查和检验	95.62	96.88	96.25
疾病和诊断	74.17	75.74	74.95
症状和体征	95.71	97.75	96.72
治疗	78.82	82.85	80.78
综合	91.45	93.48	92.46

整体识别性能较优。具体到各类实体结果来看,“检查和检验”和“症状和体征”的识别效果最好,F1 值均超过 96%,“疾病和诊断”的实验结果最差,F1 值仅为 74.95%。

分析识别错误的测试结果,主要原因:一是电子病历数据集实体类别不平衡,“疾病和诊断”这类实体的训练样本量为 487 个,仅占训练样本总量的 2.37%,影响构建模型;二是医学实体的嵌套和不连续性导致识别错误,如大部分“疾病和诊断”实体与“身体部位”“症状和体征”存在着关联与重合,如“左侧股骨粗隆间骨折”“右胸部外伤”等,导致实体边界识别错误。

3.4.5 实例分析 为了进一步验证本文模型的优越性,从商丘市第一人民医院选取 50 份电子病历,通过去隐私化、数据清洗等过程,获得一个结构化的医疗无标注数据集。运用本文生成的电子病历 NER 模型对数据集进行实体标注,统计 5 类命名实体,识别结果准确率为身体部位 89.86%、检查和检验 92.74%、疾病和诊断 70.13%、症状和体征 83.05%、治疗 76.56%。整体表明该模型在真实数据中能够得到较好的效果。“粪常规”“肝功生化”“胸片”“心脏超声”“冠脉 CTA”“心内电生理检查 + 射频消融术”等实体能够准确识别;但对于“血(常规)”“尿(常规)”未能准确识别,主要是由于电子病历中经常出现略写、简写等形式,造成模型识别错误。

综合来看,本文模型的 F1 值达 92.46%,表明

4 结语

中文医疗电子病历的实体是医学知识的重要组成部分。提升医疗领域文本的实体识别效果对医疗知识挖掘与组织具有至关重要的作用。本文设计 ERNIE - BiGRU - Attention - CRF 模型用于中文医疗电子病历的 NER 研究。首先采用 ERNIE 模型 3 级掩码的方式, 获取词向量; 其次, 引入 BiGRU 模块和 Attention 模块来解决长序列和重点特征的识别; 最后, 运用 CRF 模型获得全局最优标注序列。在公开的医疗电子病历数据集上与现有的部分代表性模型的实验结果进行对比, 本文所提出模型的 *F1* 值最高, 体现了 ERNIE - BiGRU - Attention - CRF 模型的有效性。

尽管本文的方法在实验中和真实数据中取得较好效果, 但模型中实体类型不平衡性问题和医学概念的嵌套、简写、缩写和不连续性等问题仍影响识别效果。因此, 后续可以构建均衡电子病历数据集, 融入多特征和医学知识优化识别效果, 开展实体补齐研究, 提升模型的语义理解能力和鲁棒性。

利益声明: 所有作者均声明不存在利益冲突。

参考文献

- 张芳丛, 秦秋莉, 姜勇, 等. 基于 RoBERTa - WWM - BiLSTM - CRF 的中文电子病历命名实体识别研究 [J]. 数据分析与知识发现, 2022, 6 (Z1): 251 - 262.
- 刘浏, 王东波. 命名实体识别研究综述 [J]. 情报学报, 2018, 37 (3): 329 - 340.
- 杜晋华, 尹浩, 冯嵩. 中文电子病历命名实体识别的研究与进展 [J]. 电子学报, 2022, 50 (12): 3030 - 3053.
- BIRUNTHA S, REVATHY M, MAHABOOB R, et al. Comprehensive review of deep learning techniques in electronic medical records [EB/OL]. [2023 - 12 - 09]. https://www.itm-conferences.org/articles/itmconf/abs/2023/06/itmconf_icdsac2023_03001/itmconf_icdsac2023_03001.html.
- 许思特, 孙木. 基于命名实体识别与 Neo4j 的中文电子病历知识图谱构建和应用 [J]. 医学信息学杂志,

- 2022, 43 (12): 50 - 56.
- CODEN A, SAVOVA G, SOMINSKY I, et al. Automatically extracting cancer disease characteristics from pathology reports into a disease knowledge representation model [J]. Journal of biomedical informatics, 2009, 42 (5): 937 - 949.
- BODENREIDER O. The unified medical language system (UMLS): integrating biomedical terminology [J]. Nucleic acids research, 2004, 32 (1): D267 - D270.
- SAVOVA G K, MASANZ J J, OGREN P V, et al. Mayo clinical text analysis and knowledge extraction system (cTAKES): architecture, component evaluation and applications [J]. Journal of the American medical informatics association, 2010, 17 (5): 507 - 513.
- CORTES C, VAPNIK V. Support - vector networks [J]. Machine learning, 1995, 20 (3): 273 - 297.
- FINE S, SINGER Y, TISHBY N. The hierarchical hidden Markov model: analysis and applications [J]. Machine learning, 1998, 32 (1): 41 - 62.
- LAFFERTY J D, MCCALLUM A K, Pereira F C N. Conditional random fields: probabilistic models for segmenting and labeling sequence data [C]. San Francisco: International Conference on Machine Learning, 2001.
- GU J, WANG Z, KUEN J, et al. Recent advances in convolutional neural networks [EB/OL]. [2023 - 04 - 09]. <http://arxiv.org/abs/1512.07108v6>.
- SCHMIDHUBER J. Deep learning in neural networks: an overview [EB/OL]. [2023 - 04 - 09]. <http://arxiv.org/abs/1404.7828v3>.
- DEVLIN J, CHANG M W, LEE K, et al. Bert: pre - training of deep bidirectional transformers for language understanding [J]. Computation and language, 2018 (10): 4171 - 4186.
- MIKOLOV T, CHEN K, CORRADO G, et al. Efficient estimation of word representations in vector space [EB/OL]. [2023 - 04 - 09]. <http://arxiv.org/abs/1301.3781v1>.
- PENNINGTON J, SOCHER R, MANNING C D. Glove: global vectors for word representation [C]. Doha: 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP), 2014.
- 陈娜, 孙艳秋, 燕燕. 结合注意力机制的 BERT - BiGRU - CRF 中文电子病历命名实体识别 [J]. 小型微型计算机系统, 2023, 44 (8): 1680 - 1685.

(下转第 100 页)

4 结语

医院图书馆开展基于科学知识图谱的学科服务, 既有助于满足医院临床、科研、教学和管理的需求, 也是图书馆员职业价值的体现。科学知识图谱能够帮助馆员实现从文献服务的学科服务到知识发现的学科服务转变, 是数据驱动和技术赋能的精准化学科服务的实现路径之一。构建医院机构知识库, 整合科研数据, 嵌入可视化分析功能, 进行医院学科分析, 将是医院图书馆学科服务能力的主要体现。

医院图书馆必须重视知识管理相关素养教育, 做好图书馆学、情报学和信息管理专业人才的引进和馆员职业培训, 提升学科馆员知识发现和数据挖掘软件工具的实用技能, 以及对于数据产品知识发现功能的评价和应用能力。医院图书馆必须建立并完善学科服务模式, 依托高质量学科服务队伍实现高质量学科服务。随着信息技术更深入地赋能知识管理技术, 更智能化的迭代知识产品将得到应用。学科服务也将面临更多的机遇和更大的挑战。

利益声明: 所有作者均声明不存在利益冲突。

参考文献

1 李芳芳. 医药类高校图书馆精准化学科服务发展现状及

服务模式研究 [J]. 大学图书馆学报, 2024, 42 (1): 69-75.

2 马永强, 王秀波, 侯胜超, 等. 英国 NHS 医学知识服务战略框架及对我国医学图书馆的启示 [J]. 医学信息学杂志, 2023, 44 (5): 82-86.

3 张妍, 孙晶晶, 张建平, 等. 军队院校图书馆智慧化学科服务实现路径 [J]. 中华医学图书情报杂志, 2022, 31 (4): 71-75.

4 贾宣东. 知识管理及其实践 [J]. 中国质量, 2022 (8): 60-65.

5 谭英, 赵婉忻, 师俏梅, 等. 基于 DIKW 模型的高校图书馆学科服务模式优化研究 [J]. 大学图书馆学报, 2023, 41 (1): 53-57.

6 国家卫生健康委关于印发《三级医院评审标准 (2022 年版)》及其实施细则的通知 [EB/OL]. [2023-12-15] https://www.gov.cn/zhengce/zhengceku/2022-12/18/content_5732583.htm?eqid=d1eb0fb1000cf0e0000000036458bffd.

7 陈悦, 刘则渊. 悄然兴起的科学知识图谱 [J]. 科学学研究, 2005, 23 (2): 149-154.

8 宋涯含, 吴云霞, 范道洋. 基于 VOSviewer 生物医学领域 3D 打印的知识图谱分析 [J]. 中国组织工程研究, 2021, 25 (15): 2385-2393.

9 LI C, GENG M, LI S, et al. Knowledge mapping of surgical smoke from 2003 to 2022: a bibliometric analysis [J]. Surgical endoscopy. 2024, 38 (3): 1465-1483.

10 张艳芬, 冯蕾. 医院图书馆基于机构知识库助力护理科研高质量发展的学科服务探析 [J]. 中华医学科研管理杂志, 2023, 36 (6): 461-464.

(上接第 82 页)

18 梁怀众, 庄培锋, 彭宏, 等. 基于知识图谱与 BERT - BiLSTM - CRF 模型的中文电子病历实体识别研究 [J]. 中国数字医学, 2022, 17 (8): 43-47.

19 张华丽, 康晓东, 李博, 等. 结合注意力机制的 Bi - LSTM - CRF 中文电子病历命名实体识别 [J]. 计算机应用, 2020, 40 (S1): 98-102.

20 SUN Y, WANG S, LI Y, et al. Ernie: enhanced representation through knowledge integration [EB/OL]. [2023-04-09]. <http://arxiv.org/abs/1904.09223>.

21 CHO K, VAN MERRIËNBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder - decoder for statistical machine translation [EB/OL]. [2023-04-09]. <http://arxiv.org/abs/1406.1078>.

22 张付领. 结合 ERNIE2.0 的医疗中文命名实体识别模型 [J]. 电子设计工程, 2023, 31 (4): 38-42.

23 刘安栋, 彭琳, 叶青, 等. 电子病历命名实体识别研究进

展 [J]. 计算机工程与应用, 2023, 59 (21): 39-51.

24 廖涛, 马文祥, 张顺香. 基于多特征融合的双通道医疗实体识别 [J]. 计算机工程与设计, 2023, 44 (10): 3146-3152.

25 陈嵩. 基于 Lattice - BiGRU 的电子病历命名实体识别研究 [D]. 银川: 北方民族大学, 2023.

26 罗凌, 杨志豪, 宋雅文, 等. 基于笔画 ELMo 和多任务学习的中文电子病历命名实体识别研究 [J]. 计算机学报, 2020, 43 (10): 1943-1957.

27 唐国强, 高大启, 阮彤, 等. 融入语言模型和注意力机制的临床电子病历命名实体识别 [J]. 计算机科学, 2020, 47 (3): 211-216.

28 林令德, 刘纳, 徐贞顺, 等. 基于多层动态融合的中文医疗命名实体识别 [EB/OL]. [2023-11-22]. <http://kns.cnki.net/kcms/detail/11.2127.TP.20230825.1143.006.html>.