

基于深度学习的病历质量控制系统设计

罗明

(广东省梅州市人民医院, 广东 梅州 514000)

摘要: 医疗领域患者的主诉信息是医疗文本分类工作的关键, 能为智慧医疗和信息文本归类提供有力的支持; 近几年来随着深度学习的发展应用, 基于传统深度学习技术的全流程病历质量控制模型层出不穷, 但传统模型存在很多缺点和局限性, 诸如训练速度慢、精度损失、过拟合和无法处理大规模数据的问题, 因此, 引入改进的深度学习算法; 指南指导下基于深度学习的全流程病历质量控制系统设计实验结果为: 将词向量设置成 160 时双向循环神经网络模型效果最优, 准确率为 84.9%; BiGRU-SA MODEL, 精准确度受向量维度的影响并不大; 而改进的文本分类式前馈神经网络模型, 精准确度在其进行第 3 次和第 4 次迭代更新时, 发生指数级增长, 并在第 3 次迭代时, 精度达到理想值, 为 83%; 随着迭代次数的增加, 模型准确率呈现先增大后减小的趋势, 在进行第 6 次迭代时模型效果最优, 准确率为 84.9%; 优化后的全流程病历质量控制模型在变动率指标下的面积的值、准确率、 F_1 、召回率四项指标值都有了一定的提升, 以上结果能更好地解决过拟合和特征信息丢失的问题, 并且实现全流程病历质量的控制。

关键词: BiGRU-SA; 全流程病历; TextCNN; 医疗诊断设备; 质量

Design of Medical Record Quality Control System Based on Deep Learning

LUO Ming

(Guangdong Meizhou People's Hospital, Meizhou 514000, China)

Abstract: The main complaint information of patients in medical field is key to medical text classification work, which can provide a strong support for smart healthcare and information text classification. In recent years, with the development and application of deep learning, full process medical record quality control models based on traditional deep learning technologies have emerged one after another. However, traditional models have many shortcomings and limitations, such as slow training speed, accuracy loss, overfitting, and inability to process large-scale data. Therefore, an improved deep learning algorithm is introduced. Under the guidance of the guide, the experimental result of the whole process medical record quality control system based on deep learning is that, when the word vector is set to 160, the Bidirectional recurrent neural network model is the best, with an accuracy rate of 84.9%. The accuracy of BiGRU-SA Model is not significantly affected by the vector dimension. Then the accuracy of the improved text categorization feed-forward neural network model increases exponentially when it is updated in the third and fourth iterations, and its precision reaches the ideal value of 83% at the third iteration. With the increase of iteration number, the accuracy of the model shows the trend of increasing first and then decreasing later. In the sixth iteration, the model performs best with an accuracy of 84.9%. The optimized whole process medical record quality control model has achieved certain improvements in four indicators of area, accuracy, F_1 , and recall under the rate of change index. The results show that the problems of overfitting and feature information loss are better solved, and the control of entire process medical record quality is achieved.

Keywords: BiGRU-SA; full process medical records; TextCNN; medical diagnostic equipment; connotative quality

0 引言

随着信息技术的不断发展, 智能化的疾病辅助诊断在解决专业医师人力缺乏的同时, 有效提升了诊疗效率, 这样能够促进整体医疗水平的快速提高。医疗辅助设备的广泛应用, 使得医疗辅助数据呈现出快速的增长趋势。同时, 这些数据中也蕴含了大量有价值的信息, 不仅有利于患者康复, 更能促进医疗水平的整体提升。针对相关全流程病历质量出现的临床诊疗效率低, 医生无法及时准确的进行诊断的问题, 以及相关设备在药液质量方面出现的设备温

度和压力不可调或者精度不够准的问题, 设计了一种基于深度学习的全流程病历质量控制模型, 其在医疗领域中应用前景广阔^[1-2]。

文献 [3] 提出了一种深度学习方法和一种医学主题挖掘方法来从无文本病历中自动预测疾病代码, 结果显示, 在重症监护医疗信息数据集上的 F_1 分数比最先进水平提高了 5%^[3]。文献 [4] 提出了一种新的电子健康记录生成器, 应用了一种过滤策略来增强低患病率临床概念的训练, 结果显示, 所提出的模型优于最先进的方法, 在保留真实记

收稿日期: 2023-06-19; 修回日期: 2023-07-10。

基金项目: 梅州市人民医院科研培育项目(PY-C2022006)。

作者简介: 罗明(1986-), 男, 大学本科。

引用格式: 罗明. 基于深度学习的病历质量控制系统设计[J]. 计算机测量与控制, 2023, 31(11): 235-241.

录的性质方面有显著的改进^[4]。文献 [5] 提出一种基于异构图卷积的文本分类技术以开展中医电子病历构建, 结果显示, 该模型在召回率以及准确率上比改进前算法提升超过了 2%^[5]。文献 [6] 从区块链技术出发, 提出了基于区块链变革性干预类型的病历信息共享模型, 为病历信息管理手段提供了参考^[6]。文献 [7] 通过对当前最先进的深度神经网络模型的改进和调整, 实现了对抑郁患者的辅助诊断, 并将其用于临床, 并将其用于临床, 获得了良好的结果。通过对比研究, 本项目所提方法在抑郁-正常人脑 MRI 识别中的应用效果, 证明本项目所提方法在抑郁-正常人脑 MRI 识别中的应用效果^[7]。

因此, 研究将辅助诊断设备作为研究对象, 并对病历模型展开分析。首先对双向循环神经网络 (BiGRU-SA, bi-directional recurrent neural network) 模型和文本分类式前馈神经网络 (TextCNN, transformation-extraction-convolutional CNN) 模型的结构进行分析, 其后对模型制定公式, 对优化后的混合深度学习模型进行分析, 以提升全流程病历质量控制系统的稳定性并提高其临床诊疗效率。深度学习辅助决策医疗器械临床试验有效性指标一般考虑验证确认诊断准确度评价指标, 即在诊断试验中区分不同疾病状态的能力。

1 基于深度学习的全流程病历质量控制系统设计

1.1 基于 BiGRU-SA 的全流程病历质量控制模型

全流程病历质量控制模型可以帮助医生更准确地诊断疾病, 提高治疗效果, 并且比人类医生更快地发现潜在的问题, 从而减少误诊、漏诊的情况。以下是一些全流程病历质量控制模型的好处, 分别是帮助医生提高诊断准确性, 通过全流程病历质量控制模型可以通过分析大量数据来预测一个患者可能患有某种疾病的可能性^[8]。这样, 医生就可以提前发现潜在的问题, 从而采取相应的治疗措施。并提高治疗效率, 全流程病历质量控制模型可以根据患者的历史症状和检查结果来预测患者可能患有某种疾病。这样, 医生就可以提前采取措施来缓解症状或预防并发症的发生^[9]。其后, 提高医疗质量, 全流程病历质量控制模型可以通过分析大量数据, 来预测一种疾病或症状可能出现的概率。这样, 医生就可以提前采取措施来缓解患者的痛苦和提高治疗效果。就可以更多地专注于治疗患者, 在有限的时间内提高治疗效果。

中文分词 (CWS, chinese word segmentation), 它是对一个语句进行切割, 从而获得单个单词, 能起到关键作用的方式为, 以自然语言及数据挖掘进行差异化处理^[10]。中英文在语序语义方面差异明显, 英文语言的句子里, 所有的字都会被空出来, 一个字就是一个字, 而中文语言的句子里, 没有自然的分割线, 也没有清晰的识别标志, 只能人工进行分割。这一部分主要包括三个方面: 基于规则的切分法, 基于概率和统计的切分法, 以及基于语义的切分法。当前, 常用的基于 Jieba 的自动分割方法主要采用基于前缀词典的语句分割方法, 已有的算法对已有的数据进行

处理, 并利用该算法对已有的数据进行处理^[11]。它支持简单繁体的切词, 还支持定制词典, 并且还支持精确模式、全模式和搜索引擎模式三种切词模式, 在业内受到了广泛的欢迎。去停用词, 是数据预处理过程中不可或缺的一环, 由于并不是所有的词语都可以表达出原本的文字意思, 如助词 (所以、的、了等)、语气词 (啊、哪等) 等都是没有作用和意义的词, 在研究中, 这些词被称作停用词, 不仅会降低文本关键词的密度, 还会在某种程度上对后续文本分析的效果产生影响, 因此, 就可以将它们从文本中删除。要实施解禁词汇, 首先要建立解禁词汇列表, 当前, 网络上有许多高品质的中文解禁词汇列表, 研究可以从网络上下载一套解禁词汇列表, 以供解禁词汇检索。通过将中文分词任务转化为一个字符序列标注任务, 可以进一步将该任务看作一个分类问题, 即为字符序列中的每个字符确定标签分类的问题, 最后实现用神经网络解决该多分类问题。谷歌研究小组于 2013 年推出 Word2Vec 框架, 该框架使用深度神经网络将文字信息转换成词汇, 并将文字信息转换成一个低维的维度, 从而实现对文字信息的有效表达^[12]。Word2Vec 的学习过程中, 有两个学习过程: 一个是 CBOW, 一个是 Skip-gram。

门循环单元 (GRU, gate recurrent unit) 是 LSTM 模型一个较成功的变种, 由 Cho, Gulcehre 等人于 2014 年提出 GRU 只有两个门即更新门和重置门, 更新门就相当于 LSTM 模型中输入门和遗忘门的合并, 并且新增了重置门, 取消了输出门。更新门的作用是控制前面记忆单元中的状态信息被带入到后面单元的程度, 更新门的值越大说明被带入的状态信息越多^[13]。重置门的作用是控制前面状态信息的忽略程度, 重置门的值越大说明忽略的越少, 换句话说也就是对当前的输出影响越大。GRU 模型结构, 如图 1 所示。




图 1 GRU 的模組的作业图解

图 1 中, x_t 与 h_t 分别表示即时的输入与输出, 而上一时刻的隐藏层的信息输出为 h_{t-1} , s_t 与 r_t 在 GRU 模组中为更新门和重置门, 活化函数用 σ 和 \tanh 表示, s_t 和 r_t 的公式, 如式 (1) 所示。

$$\begin{cases} s_t = \text{sigmoid}(W_s \cdot [h_{t-1}, x_t]) \\ r_t = \text{sigmoid}(W_r \cdot [h_{t-1}, x_t]) \end{cases} \quad (1)$$

式 (1) 中, W_s 和 W_r 为门控对 h_{t-1} 和 x_t 的系数, 即需学习的权重矩阵。BiGRU 是一个双程神经网络模式, 可以更好

地捕捉病人的抱怨情境中的意义依存关系。在此基础上，提出了一种基于自我注意的新方法，即通过自我注意来降低对外界信息的过度依赖性，提高了语义特征和语句的内在关联性。在 BiGRU 的基础上，提出了一种新的医学诊断方法——BiGRU-SA，并将其应用于医学诊断中。在 BiGRU-SA 模式中，利用自我注意的作用，捕捉病人抱怨情境中的语义相关性。通过对文本中各个词进行加权处理，提高了文本的语义表达能力和语义表达能力^[14-15]。在此基础上，提出了一种基于二维 GRU 的病案情境关联分析方法。在此基础上，利用 BiGRU-SA 方法，实现了对医学信息的快速识别。利用自我关注的思想，能够更好地把握病人在不同背景下的陈述内容，进而提高对病人陈述内容的识别精度。BiGRU-SA 模型架构，如图 2 所示。

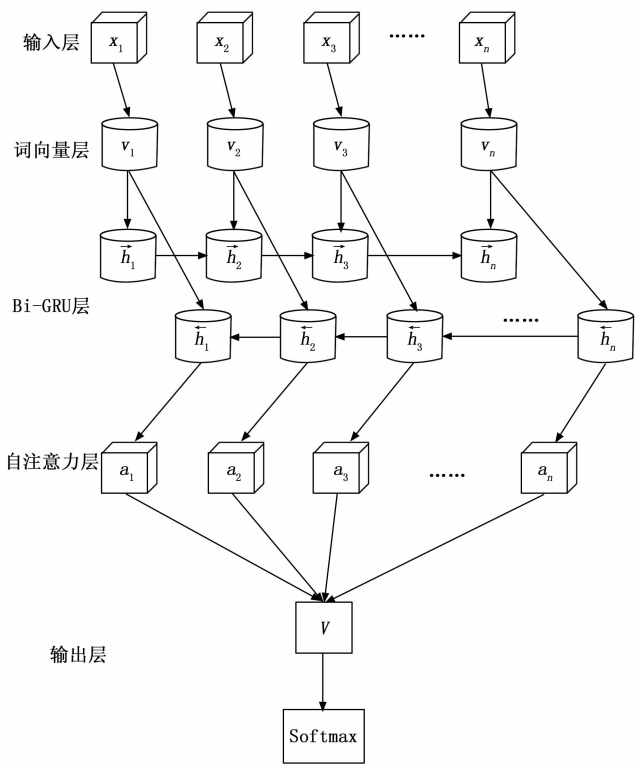


图 2 BiGRU-SA 模型架构图

图 2 中，第一个层次是输入层次，将病人的诉求输入到该模型中；第二个层次是词向量构建层次，将病人诉求降维后，将诉求转化为低维向量；第三个层次是 BiGRU 的网络结构，利用 BiGRU 提取病人诉求表征；最后一个层次是自关注层次，利用 Attention 加权函数，将诉求的词汇和表达的特征融合在一起；最后一个层次是输出层次，将病人主诉的描述结合起来，最后一个层次是输出层次，给出对病人主诉的描述。

1.2 基于 F-TextCNN 的全流程病历质量控制模型

TextCNN 是一种流行的深度学习模型，它的结构比较简单，包括嵌入层、卷积层、池化层和全连接层。它通过将文本数据输入到嵌入层，在此基础上，利用卷积方法抽取语句中的字符，再利用极大浸渍方法抽取一维矢量，再

利用完全连通层获得其结果。TextCNN 模型的主要特点是利用了卷积层和池化层来提取文本的特征，并使用了全连接层来生成最终的输出^[16-17]。这种模型结构简单，适用于处理简单的文本任务，如文本分类、命名实体识别等。

当前广泛使用的 TextCNN 具有良好的文字识别性能，但由于其对病症的表征缺失，因此，研究通过构建 F-TextCNN 来解决这个问题。F-TextCNN 旨在构建一个能够更好地表征病症的模型，使其具有更高的识别精度。在 F-TextCNN 中，研究使用一种新的特征提取方法，这种方法能够有效地提取病症特征，从而提高文字识别的性能。同时，研究还使用了一种新的池化方法，使得模型能够更好地提取病症特征，从而提高文字识别的准确性。F-TextCNN 能够有效地解决文本识别中由于缺乏病症表征而导致的问题，使其具有更高的性能和更好的准确率^[18-19]。文本 CNN 的模式架构，可分为嵌入层、卷积层、池化层及完全连通层。TextCNN 中的卷积神经网络，其主要功能在于抽取文本中的语义信息，而无须像其他的机器学习算法那样，对文本中的语义信息进行独立的处理。TextCNN 的集合层可采用最大集合法、平均集合法等多种方式，其中最常见的是最大集合法，即通过抽取特征图中的极大值来捕捉最关键的特性。通过对多个从卷积图像中提取出的多个特征图进行融合，可获得多个一维矢量。最大融合方法具有不受时间限制、不受时间限制等优势，能够有效地降低建模中的参数个数和过拟合，但也有一定的局限性^[20]。故而，TextCNN 模型结构，如图 3 所示。


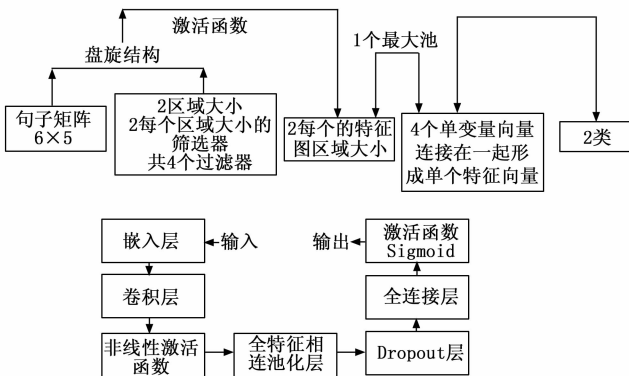


图 3 TextCNN 模型原理及其架构图



如图 3, 在该算法中, 嵌入层采用了事先学习好的词向量, 并将其构造成一个矩阵, 并将其用作一个单词的代表。把数据集上的每一个单词都用一个向量来表达, 这样就可以获得一个 $N \times K$ 的嵌入矩阵 M , 在该矩阵中, 每一行都是词向量。在这些情况下, 因为 TextCNN 使用最大池化进行处理, 避免了池化过程中对病症特性的影响。为了解决这个问题, 从卷积层中抽取出来的所有的特征被联系起来, 保证了症状特征的完整, 并用准确率、召回率以及 F_1 指标来评价该模型的优劣。在 F-TextCNN 框架下, 先将疾病相关的数据输入到嵌入层, 然后输出一个非线性激励函数, 然后将整个内嵌层连接到嵌入层, 然后在 Dropout 层正则化学习, 从而有效地避免了神经网络的过拟合问题。在经过任何一批学习后, 将其中的隐藏结点舍弃掉, 从而降低了隐藏结点间的相互依赖程度。最终, 在整个联结层次上, 利用激发函数 Sigmoid 对两个不同的特征进行二次分类, 得到的结果在两个不同的特征量之间更优。该方法对病人的疾病信息进行了词汇矢量建模, 然后将病人的疾病信息转化为一个 2D 的矩阵, 并在该模型的输入层利用“补零”原理, 使该矩阵保持固定长度, 也就是一个最大值 $N = 824$, 其他句子小于 824 时, 再用 0 进行填充。在该方法中, 选择 3 个大小不一的卷积核, 通过卷积运算得到词向量的特征。改进的最终输出类别概率, 如式 (2) 所示。

$$C = \sum_{i=1}^{n-k+1} C_i \quad (2)$$

式 (2) 中, C_i 为卷积后的特征图, $n-k+1$ 为池化层高度, 故而, 池化的结果就是将特征图进行全连接。

1.3 基于 BiGRU-SA 和 F-TextCNN 的全流程病历质量控制混合模型

将 F-TextCNN 与 BiGRU-SA 相结合, 以两种新的检测技术为核心, 在此基础上, 将 F-TextCNN 与 BiGRU-SA 相结合, 以达到对疾病进行早期诊断的目的。F-TextCNN 是一种基于深度神经网络的医疗影像数据分析方法, 能够对医疗影像数据进行有效地分析和处理。BiGRU-SA 是一个利用机器学习技术, 从病人身上提取出的信息, 帮助医师做出正确的判断。这两种技术各有其优点, 可为医疗辅助诊断工作提供有力支撑。此次研究考虑综合运用 F-TextCNN 与 BiGRU-SA 模型, 实现对疾病的诊疗, 为临床诊疗提供新的思路。在进行训练的时候, 将两个模型分别进行, 两个模型之间互相独立, 不会受到任何的影响。在训练完毕之后, 将两个模型进行分类结果进行融合, 因为神经网络模型最终的输出是一个概率值, 所以将两个分类结果进行加权平均, 就可以得到最终的输出。混合模型流程, 如图 4 所示。

图 4 中, 针对混合模型流程, 首先由嵌入层到卷积层再到池化层, 对特征信息进行池化, 而后加入到全连接层, 再由 F-TextCNN 模型进行输出。同理, BiGRU-SA 模型输出后, 一起进入到加权平均输出层, 加权后, 结束模型工作。将两个模型的输出结果进行融合做加权平均操作, 可减少误差, 活化函数是在神经细胞中, 将输入的权重相

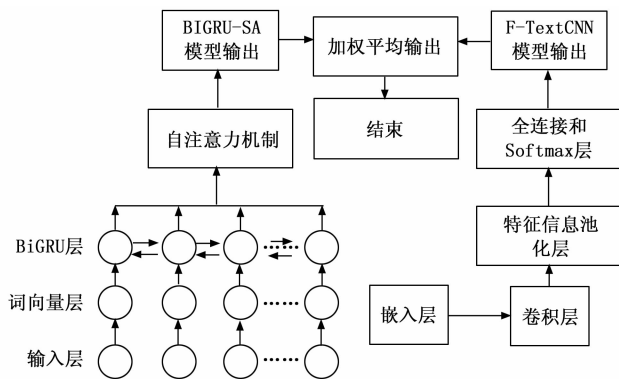


图 4 混合模型流程框架结构

加后, 被用于一个功能的运算后, 该功能就是活化函数。在激励函数为非线性的情况下, 神经网络能够任意近似大部分的复合功能。但是, 若使用一维线性激励函数, 则其结果是一维非线性激励函数, 因而不能近似复函数。因此, 在神经网络中加入一个激励函数, 就是要将一个非线性因子加入到神经网络中, 这样才能更好地处理一些更复杂的问题。在不引入激励函数的情况下, 神经网络与原感知器之间没有什么区别。由 BiGRU-SA 模型和 F-TextCNN 模型的输出公式, 如式 (3) 所示。

$$\begin{cases} y_1 = \text{softmax}(\mathbf{W}_{y_1} * P_1 + b_{y_1}) \\ y_2 = \text{softmax}(\mathbf{W}_{y_2} * P_2 + b_{y_2}) \end{cases} \quad (3)$$

式 (3) 中, \mathbf{W}_y 是权重系数矩阵, b_y 是代表相应的偏置, 进而达到预测类别的效果。则 F-TextCNN 和 BiGRU-SA 相结合的医疗辅助诊断混合模型的输出公式, 如式 (4) 所示。

$$\hat{y} = \text{avg}(y_1, y_2) \quad (4)$$


式 (4) 中, \hat{y} 为最终输出的类别, 基于 BiGRU 和自我关注的医学诊断算法, 因其能够高效地理解医学语句, 从而提高了医学诊断的精度。然而, 由于网络的复杂性, 因此分析数据与分析效率也有所提高。此外, 由于算法能够从大量数据中学习, 因此可以更好地理解临床情况, 从而提供更准确的诊断结果。因此, 基于 BiGRU 和自我关注的医学诊断算法, 不仅能够提高医学诊断的精度, 还可以提高对数据的分析与分析效率。然而, 尽管 F-TextCNN 具有很高的准确性, 但其不能有效地提取文本中的语境信息, 而且语句可理解度不高。此外, 研究还提出了一种基于遗传网络的遗传网络建模方法, 它的学习方法是基于遗传网络的遗传网络建模方法。

2 实验与分析


2.1 指南指导下的基于 BiGRU-SA 的全流程病历质量控制模型分析

在此基础上, 利用国家“知识地图”和“语义学”会议上的正式医学文字库, 构建基于“医学文字”的全过程医学文件内容质控系统。数据为患者病情描述文本分类数据集, 共有 40 000 条数据, 将数据进行划分后, 可以获得

训练集 34 000 条数据，测试集 4 300 条数据，其中包含了艾滋病、白瘫风、不孕不育、产科、癫痫、耳鼻喉科、肺癌、妇科炎症等 45 个疾病或科室的分类数据。基于 BiGRU-SA 的全流程病历质量控制模型的参数优化实验，如图 5 所示。



(a) 词向量维度实验折线图



(b) 迭代次数实验折线图

图 5 参数优化实验图

图 5 (a) 中，横轴表示的是词向量维度的选择，它们分别为 25、50、100、150、200、250、300 的向量维度，而纵轴表示的是正确率。可以看出，当词向量设定为 160 时，BiGRU-SA 模型的效果最优，其正确率为 84.9%。图 5 (b) 中，水平坐标为迭代次数，垂直坐标为精度。随着迭代次数的增加，模型精度出现了先增大后减小的趋势，在第六次迭代时，模型效果最优，精度为 84.9%。各对比模型之间随着迭代次数的变化而变化的准确率折线图，如图 6 所示。

图 6 中，横轴代表迭代次数，纵轴代表准确率，展现了所有模型随着迭代次数的变化而变化的模型性能。通过对比五组模型实验结果的准确率、召回率和 F_1 值，BiGRU-Sa 在 6~7 次迭代中，可达到最高精度，为 85.4%。而 Selt-Attention Model 在第一次迭代时的精度最高，为 82.7%。且 Selt-Attention Model 和 LSTM Model 都随着迭代的增加，精度都呈现下降的趋势。基于 LSTM 的全流程病历质量控制模型的准确率较低，而基于 GRU 模型、Self-Attention 模型和 BiGRU 模型的准确率依次递增。基于自注

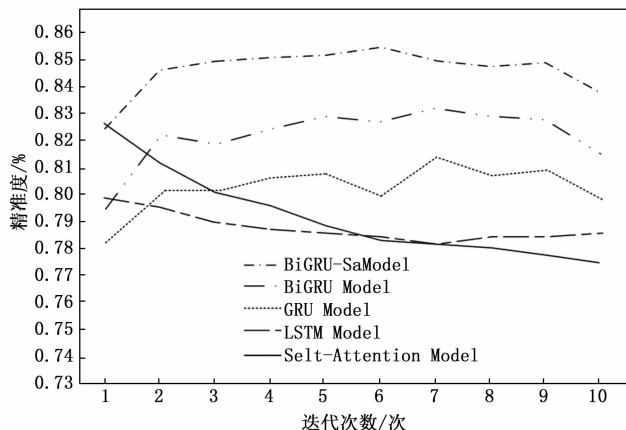


图 6 各对比模型之间随着迭代次数的变化而变化的准确率折线图

意力机制 BiGRU 模型具有更高的精度。BiGRU-SA 模型是基于 BiGRU 模型加入了自我注意机制，能够利用自我注意机制层次赋予的权值来凸显疾病症状的特征性信息，使其能够更好地聚焦于疾病症状词汇而忽视与疾病症状无关的特征性信息。通过将 GRU 和 LSTM 模型进行比较，可以看出，GRU 模型在降低 LSTM 模型结构的同时，仍然保留了其原有的计算效果，降低了计算量，从而使得 GRU 模型的运行时间更短，而且效率更高。在图中，根据 BiGRU 和 GRU 模型比较可以看出，因为 BiGRU 对输入语句中双向进行计算，能够提取到更精确的文本特征，因此，双向门限循环神经网络模型具有更高的精度，因为它具有更好的结构，能够捕获更深层次的信息，并且可以有效地处理序列数据。此外，加入自关注策略后，该模型的识别精度也得到了显著的提高，表明它对于医学文字的识别效果也非常优秀。通过对不同的自关注策略进行实验，可以发现不同的策略下，模型的识别效果也会有所不同。因此，选择最合适的自关注策略可以显著提高模型的识别精度。

2.2 指南指导下的基于 F-TextCNN 的全流程病历质量控制模型分析

为了对该模式的效能进行检验，研究利用了 36 000 个训练集和 4 500 个健康医学文字资料进行了分析。研究首先使用了 TextCNN 算法对这些数据进行了预处理，包括清洗和特征选择，然后将数据集分为训练集和测试集。接着，研究采用了多种算法（如交叉验证、单调性测试、准确率测试等）来评估这些模型的性能。最后，研究使用了多种分析方法（如相关性分析、线性回归等）来探究模型之间的关联和差异。通过这些分析，研究得出了一些结论，该模式在预测准确性、稳定性和可解释性方面表现都很出色。

在此基础上，将 F-TextCNN，LSTM，Bi-LSTM 等神经网络方法进行识别，并将 F-TextCNN 方法应用于医学文本的识别，以检验 F-TextCNN 方法的识别效果。为了验证 F-TextCNN 模型对医疗文本的有效作用，一共设计了四组实验，使用 TextCNN，LSTM 和 Bi-LSTM 神经网络模型与

该模型进行对比分析，实验对比结果如表 1 所示。

表 1 模型对比实验结果

模型	精确度/%	召回率/%	F_1 /%
LSTM	79.6	81	80.2
TextCNN	82.1	81.1	81.7
Bi-LSTM	84.7	82.8	83.7
F-TextCNN	88.1	87.1	87.7

表 1 中，第一栏是做试验时使用的比较模型，第二栏是准确率，第三栏是召回率，第四栏是 F_1 值，所有模型的度量数据都显示在表格中。其中，F-TextCNN 的准确率为 88.1%，回收率为 87.1%， F_1 值为 87.1%， F_1 值为 87.7%。通过对 5 个试验的比较，可以看出 LSTM 模型的精度很低，而 TextCNN 和 Bi-LSTM 模型的精度是依次提高的。而 F-TextCNN 则通过改变传统 CNN 的池化模式，实现特征信息的完全链接，确保特征信息不会丢失，并有效地避免了模型的过拟合。

2.3 指南指导下的基于 BiGRU-SA 和 F-TextCNN 的病历质量控制模型分析

为了对基于 F-TextCNN 和 BiGRU-SA 的医学文本分类方法进行对比分析，研究进行了三个实验。这三个实验分别是基于 TextCNN 和 BiGRU-SA 的医学文本分类任务的对比实验、基于 F-TextCNN 和 BiGRU-SA 的医学文本分类任务的对比实验。各模型之间，随着迭代次数的变化而变化的准确率折线图，如图 7 所示。

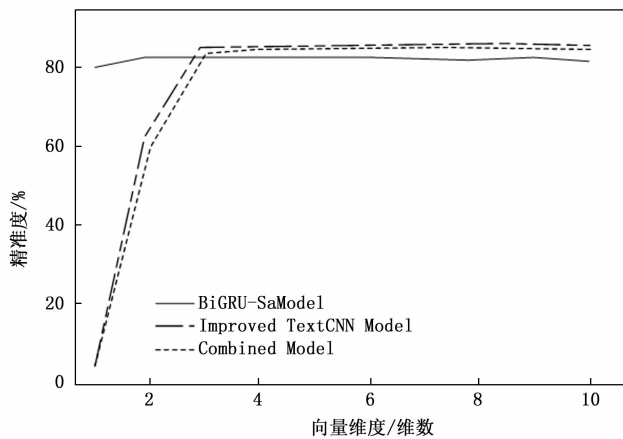


图 7 三种模型下准确率与迭代次数的关系

图 7 中，横坐标是重复试验的次数，纵坐标是精确度。可以看出，BiGRU-SA MODEL，精确度受向量维度的影响并不大。改进的 TextCNN 模型，精确度在其进行第 3 次和第四次迭代更新时，发生指数级增长，并在第 3 次迭代时，精度达到理想值，为 83%。组合模型，其迭代经历与改进的 TextCNN 模型相似，并在第 3 次迭代后，精确度达到理想值，为 82.7%。通过对三组实验的实验结果进行比较，可以看出，基于 BiGRU-SA 模型的准确率低于其他两个模型，而 F-TextCNN 神经网络模型和混合模型的准确率更

高。F-TextCNN 和 BiGRU-SA 相结合的全流程病历质量控制模型在准确性上表现更优，因为该算法能够将 F-TextCNN 和 BiGRU-SA 模型的结果进行融合，从而取长补短，平衡两者带来的负面影响，得到的结果更具有可解释性。在实际应用中，该算法可以有效地利用 F-TextCNN 和 BiGRU-SA 模型的优势，实现更加准确的医疗辅助诊断。

通过这些实验，研究可以得出结论，基于 F-TextCNN 和 BiGRU-SA 的医学文本分类方法都具有较好的性能。尽管 F-TextCNN 比 BiGRU-SA 更加灵活，但 BiGRU-SA 在处理复杂的医学文本分类任务时表现更好。因此，研究可以根据实际需求选择适合自己的模型来进行医学文本分类任务。

2.4 实例分析

为了验证研究所提基于深度学习的病历质量控制模型的在病史数据、体格检查等多项文本上的应用效果，研究选择 CCKS2020 数据集作为实验样本，该数据集包好一般项目、病史特点、诊疗过程以及出院情况等四大类，下设症状与体征、检查与检验等小类。研究采用的分类评价指标为 F_1 值，以便综合纳入准确率和召回率。表 2 为不同模型在该数据集上分类结果。

表 2 不同模型在 CCKS2020 数据集上分类结果

项目	研究所提模型	CRF	BiGRU-CRF	BiLSTM
既往病史	93.45	90.19	90.98	92.8
体格检查	91.41	73.53	89.03	90
胸部正侧位	88.61	86.58	87.21	86.69
颅脑平扫	89.16	85.64	86.02	88.69
平均值	90.66	83.97	88.31	88.54

从表 2 可知，研究所提模型在既往病史、体格检查等诸多项目的分类精度上均优于其他分类模型。平均精度高于 90%，比 CRF (conditional random field) 模型、BiGRU-CRF 以及 BiLSTM 提高了 6.69%、2.35% 和 2.12%。这表明研究所提模型能更有效地学习文本的句子结构信息与句子的表示，以便学习文本的语义特征用于分类。表 3 为电子病历中不同实体识别结果。

表 3 电子病历中不同实体识别结果

实体类型	指标	BiGRU-CRF	BiLSTM	研究所提模型
疾病与诊断	准确率/%	81.78	85.64	85.75
	召回率/%	80.31	82.48	82.78
	F_1 值/%	81.04	84.03	84.24
药物	准确率/%	83.5	87.19	87.23
	召回率/%	90.19	92.12	92.15
	F_1 值/%	86.71	89.59	89.62
手术	准确率/%	87.55	88.11	88.2
	召回率/%	90.22	91.03	91.06
	F_1 值/%	88.86	89.55	89.61
解剖部位	准确率/%	83.54	85.6	85.65
	召回率/%	83.42	86.85	86.96
	F_1 值/%	83.48	86.22	86.3

从表 3 可知, 在疾病与诊断、药物、手术以及解剖部位的实体识别结果中, 研究所提模型在三种分类性能指标上均获得了最高数值。比如在对药物的分类识别中, 该模型在准确率、召回率以及 F_1 值上, 分别比 BiGRU-CRF 模型提高了 3.73%、1.96% 和 2.91%。这表明研究所提模型有助于从分类管理中提升病历质量控制。

3 结束语

研究将全流程病历质量控制模型作为实验对象, 首先对 F-TextCNN 和 BiGRU-SA 分别进行辅助诊疗的测验, 并通过获取辅助诊疗效果的控制模型和参数寻优, 最终利用基于 BiGRU-SA 和 F-TextCNN 的全流程病历质量混合控制进行仿真评估, 以得到平滑的曲线, 在解决过拟合和特征信息丢失的情况下实现对全病历流程的质量控制。模拟结果显示, 经过 6~7 次的迭代, BiGRU-Sa 的计算精度可以达到 85.4%。其中 Selt-Attention 模型的精确度是最好的, 其精确度达到 82.7%。Selt-Attention 模型和 LSTM 模型均随迭代数的增大而减小。其中, F-TextCNN 的准确率为 88.1%, 召回率为 87.1%, F_1 值为 87.1%, 其中 F_1 值为 87.7%。通过对三组实验的实验结果进行比较, 可以看出, 基于 BiGRU-SA 模型的准确率低于其他两个模型, 而 F-TextCNN 神经网络模型和混合模型的准确率更高。组合模型, 其迭代经历与改进的 TextCNN 模型相似, 并在第 3 次迭代后, 精准度达到理想值, 为 82.7%。综上所述, 本研究提出的方法能够有效地帮助医患之间在沟通交流中克服表达障碍, 从而提高病历质量。这一方法通过 BiGRU-SA 模型提取病历信息特征, 基于 F-TextCNN 提高模型计算效率和收敛速度以分析医疗数据和病历, 从而识别出其中的关键信息, 帮助医生更好地理解患者的病情和治疗需求。此外, 该方法还能够指导医生更好地进行病历书写和管理, 提高病历质量和效率, 从而为患者提供更优质的医疗服务。

参考文献:

[1] 黄晓红, 曾俊童, 胡圣懿, 等. 人工智能辅助心电分析用于心血管病诊断的研究进展 [J]. 中国循环杂志, 2023, 38 (2): 222-226.

[2] 王 星, 刘晓燕. 医疗大数据环境下的疾病预测模型研究 [J]. 制造业自动化, 2022, 44 (7): 24-27.

[3] TENG F, MA Z, CHEN J, et al. Automatic medical code assignment via deep learning approach for intelligent healthcare [J]. IEEE journal of biomedical and health informatics, 2020, 24 (9): 2506-2515.

[4] ZHANG Z, YAN C, MESA D A, et al. Ensuring electronic medical record simulation through better training, modeling, and evaluation [J]. Journal of the American Medical Informatics Association, 2020, 27 (1): 99-108.

[5] 封红旗, 孙 杨, 杨 森, 等. 基于 BERT 的中文电子病历命名实体识别 [J]. 计算机工程与设计, 2023, 44 (4): 1220-1227.

[6] 史雅妮, 陈嘉曼, 李晨瑜, 等. 破解电子病历信息共享困境: 区块链的转型干预作用 [J]. 图书情报知识, 2022, 39 (6): 20-34.

[7] 付常洋, 王 瑜, 肖洪兵, 等. 基于深度学习与结构磁共振成像的抑郁症辅助诊断 [J]. 智能系统学报, 2021, 16 (3): 544-551.

[8] 王飞鸣. 电力系统自动化中智能技术的应用 [J]. 微型电脑应用, 2021, 37 (3): 131-133.

[9] 范 衡, 朱贵杰, 李文姬, 等. 进化计算在复杂机电系统设计自动化中的应用综述 [J]. 自动化学报, 2021, 47 (7): 1495-1515.

[10] 张立立, 杨金柱, 单禹夫, 等. 基于深度学习的计算机辅助诊断系统在嵌入式中的设计与实现 [J]. 实验技术与管理, 2022, 39 (8): 49-54.

[11] 刘礼健, 赖兰金, 刘 周, 等. 肺磨玻璃结节的计算机辅助诊断系统和多层螺旋 CT 定性研究 [J]. 实用放射学杂志, 2021, 37 (1): 42-54.

[12] 耿 然. 基于深度学习的人工智能影像辅助诊断系统对肺结节的诊断效能评价 [J]. 新乡医学院学报, 2022, 39 (11): 1031-1035.

[13] 魏一娟, 潘 宁, 陈 岩, 等. 深度学习辅助诊断系统在胸片的应用研究: 气胸及肺结节检测 [J]. 临床放射学杂志, 2021 (2): 252-257.

[14] 乐慧君, 李 芸, 林 宇, 等. 深度学习辅助诊断阻塞性睡眠呼吸暂停研究进展 [J]. 中华耳鼻咽喉头颈外科杂志, 2021, 56 (12): 1354-1360.

[15] 窦瑞欣, 黄 鹏, 白永明, 等. 基于 CheXNet 辅助诊断系统在肺部常见病诊断中的应用研究 [J]. 中国医学计算机成像杂志, 2021, 27 (6): 505-509.

[16] 王艳红, 叶海礼, 朱晨雁, 等. 一种基于深度学习的大尺寸病理图像分割诊断方法 [J]. 中国数字医学, 2021, 16 (3): 80-83.

[17] XIA M, SHAO H, WILLIAMS D, et al. Intelligent Fault Diagnosis of Machinery Using Digital Twin-assisted Deep Transfer Learning [J]. Reliability Engineering & System Safety, 2021, 215 (Nov.): 107938.1-107938.9.

[18] CHEN S, PI Y, GONG H, et al. Single-Photon Emission Computed Tomography Image-Assisted Diagnosis of Thyroid Diseases under Convolutional Network Neural Algorithm [J]. Scientific programming, 2021 (Pt.13): 4200271.1-4200271.9.

[19] 程一彤, 武 峰. 卷积神经网络在口腔医学影像领域的应用现状 [J]. 中华老年口腔医学杂志, 2022, 20 (4): 233-238.

[20] 曹 东. 基于深度学习算法的机械设备自动化关键测试影像结果识别研究 [J]. 自动化应用, 2022 (5): 17-19.