

DOI: 10.11830/ISSN.1000-5013.202007019



# 运用双向长短期记忆模型的 心拍分类算法

朱彬如, 万相奎, 金志尧, 刘俊杰, 张明瑞

(湖北工业大学 电气与电子工程学院, 湖北 武汉 430068)

**摘要:** 为提高心拍的分类效果,研究基于双向长短期记忆(BiLSTM)模型的深度学习算法.首先,采用“双斜率”法对心电信号进行预处理;然后,设计自适应阈值对预处理后的心电信号进行 QRS 波定位,并依据 R 波波峰分割截取心拍;最后,采用 BiLSTM 模型的深度学习算法对获取的心拍形态进行分类.使用 MIT-BIH 心率失常数据库验证算法有效性,实验结果表明:文中算法对正常或束支传导阻滞(N)、室上性异常(S)、心室异常(V)、融合(F)类型的敏感性分别为 98.56%,97.10%,93.33%,79.52%,特异性分别为 98.38%,98.08%,98.54%,99.65%;与传统的支持向量机等方法相比,文中算法能够进一步提高心拍分类的正确率.

**关键词:** LSTM; BiLSTM; 心拍分类; 自适应阈值

中图分类号: TP 183      文献标志码: A      文章编号: 1000-5013(2021)03-0384-07

## Heartbeat Classification Algorithm Using Bi-Directional Long-Short-Term Memory Model

ZHU Binru, WANG Xiangkui, JIN Zhiyao,  
LIU Junjie, ZHANG Mingrui

(School of Electrical and Electronic Engineering, Hubei University of Technology, Wuhan 430068, China)

**Abstract:** In order to improve the classification effect of heart beats, a deep learning algorithm based on bi-directional long and short-term memory (BiLSTM) model is studied. Firstly, the “double slope” method is used to preprocess the electrocardiogram signal. Then, an adaptive threshold is designed to perform the preprocessed electrocardiogram signal. QRS waves are located, and heartbeats are intercepted according to R wave peak segmentation. Finally, the deep learning algorithm of BiLSTM model is used to classify the acquired heartbeat shapes. MIT-BIH arrhythmia database is used to verify the effectiveness of the algorithm. The experimental results show that the sensitivity of the proposed algorithm to bundle branch block (N), supraventricular abnormality (S), ventricular abnormality (V), and fusion (F) is 98.56%, 97.10%, 93.33%, 79.52%, specificity were 98.38%, 98.08%, 98.54%, 99.65%, respectively; compared with the traditional support vector machine method, the proposed algorithm can further improve the accuracy of heartbeat classification.

**Keywords:** LSTM; BiLSTM; heartbeat classification; adaptive threshold

据《中国心血管病报告 2018》推算,我国患心血管人数达 2.9 亿,患高血压人数达 2.45 亿<sup>[1]</sup>. 仅

收稿日期: 2020-07-10

通信作者: 万相奎(1976-),男,教授,博士,主要从事生物医学工程的研究. E-mail: ruisin@hotmail.com.

基金项目: 国家自然科学基金资助项目(61571182); 湖北省自然科学基金资助项目(2015CFB449); 湖北省教育厅科学技术研究计划重点资助项目(D20151404)

2017 年,我国因心血管疾病死亡人数约为 350 万,远高于癌症致死人数,心血管疾病位居所有致死病因的首位<sup>[2]</sup>. 心电图(electrocardiogram, ECG)是临床应用最广泛的心血管疾病检查手段之一. 医生可根据心电图结果初步掌握患者的身体情况,诊断心律失常、心肌梗死等疾病.

传统基于机器学习的算法在心电信号分类领域的应用有随机森林<sup>[3]</sup>、最小相邻<sup>[4]</sup>、聚类分析<sup>[5]</sup>、隐含马尔可夫链<sup>[6]</sup>等方法. 这些方法对提取波形特征的要求很高,更多依赖于人工特征的设计. 基于深度学习的方法能够从广泛的医疗数据集中自动学习,并能从海量复杂的数据中挖掘有用的信息和规律,无需人工设计特征,可将相关人员从繁重的医疗数据中解脱出来. 近年来,卷积神经网络算法不断被应用到心电领域中. Zubair 等<sup>[7]</sup>采用卷积神经网络(CNN)提取 ECG 信号的有效特征,实现优于大多数分类算法的准确率. Kiranyaz 等<sup>[8]</sup>利用一维卷积神经网络(1D-CNN)将特征提取和分类融合统一,可对较长的 ECG 记录进行有效分类. Al Rahhal 等<sup>[9]</sup>利用深度神经网络(DNN),在网络隐含层顶层加入重构层并采用 Softmax 激活函数,提高了心律失常的分类效果. 这些算法虽然能达到不错的效果,但却忽略了心电信号在时间上的序列关系. Zhang 等<sup>[10]</sup>使用循环神经网络(RNN)与聚类分析技术处理时间序列,实现了在 MIT-BIH 心率失常数据库的有效心拍识别. 然而,心电信号的分类还要考虑局部波形与整体波形的关系, RNN 无法解决心电信号的长程依赖问题. 长短期记忆网络(LSTM)是对 RNN 的一种改进,可以较好地解决以上问题. 因此,本文基于双向长短期记忆模型的深度学习算法对心拍进行分类.

# 1 实验方法

## 1.1 心电信号的预处理

采集的心电信号往往含有基线漂移、工频干扰等噪声<sup>[11]</sup>,严重影响心电信号的特征提取和心拍识别的准确性,需在数据载入训练前进行必要的预处理. 信号预处理步骤,如图 1 所示.

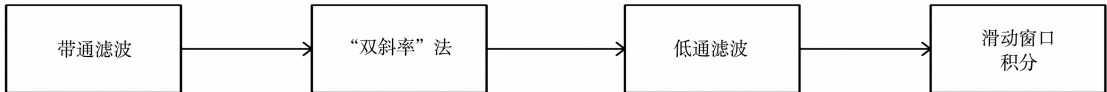


图 1 信号预处理步骤

Fig. 1 Signal preprocessing steps

利用 FIR 带通滤波去除基线漂移,低通滤波去除工频干扰等噪声. 滤波后, P 波和 T 波被明显削弱. 采用“双斜率”法<sup>[12]</sup>处理滤波后的波形,利用 QRS 波两侧波峰斜率突变的性质,在波峰左右两侧选择平均最大斜率和最小斜率;然后,用前侧最大斜率减去后侧最小斜率,后侧最大斜率减去前侧最大斜率,再取前、后两侧的最大值. 经过滤波和“双斜率”法处理后,信号幅度越来越小. 为了便于检测,通过滑动窗口积分,增大波形绝对振幅,而波形的幅值仅在纵坐标上变化,对要获取波峰横坐标的位置无明显影响. 预处理后的心电信号变成模式单一的波峰信号,波峰对应 QRS 波,比原始信号更容易检测. 预处理前、后的 ECG 信号,如图 2 所示. 图 2 中:  $U$  为电压;  $n$  为心电信号数据点的个数.

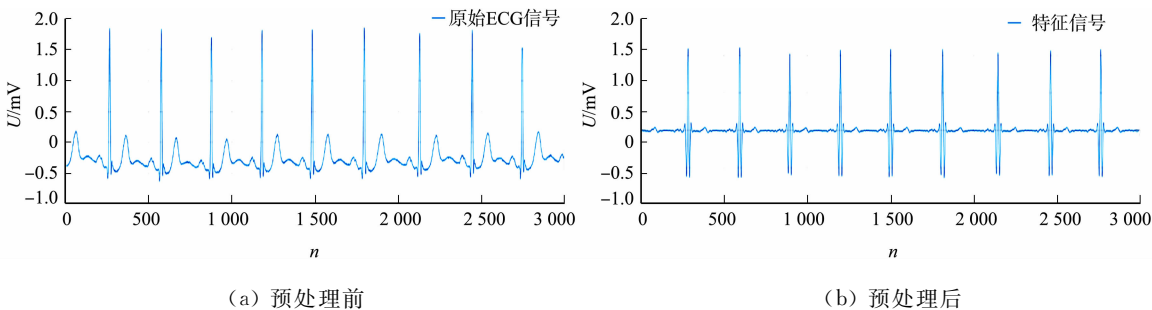


图 2 预处理前、后的 ECG 信号

Fig. 2 ECG signal before and after pretreatment

## 1.2 QRS 定位和心拍截取

经典的 QRS 波群的定位与检测方法有图形识别法、小波变换法、差分阈值法、双阈值法等<sup>[13]</sup>. 小波变换法精确度高、滤波突出,但结构较为复杂,抗干扰能力弱. 差分阈值法结构简单、运算速度快,但对预

处理的滤波要求高. 双阈值法<sup>[14]</sup>的运算速度快、精准度高、抗干扰能力强,但对波形复杂、有干扰的信号检测能力较弱.

采用一种改进的自适应阈值方法,结合差分阈值和双阈值法的优点,使自适应阈值跟随信号实时变化<sup>[15]</sup>,确定和精准定位 R 波. 当心电信号的波形超过低阈值时,即认为检测到一个 QRS 波;而当心电信号的波形超过高阈值时,则表明要适当调整阈值的数值. 为保证能检测到绝大部分的 QRS 波,要保证阈值区间能自适应波形变换并具有一定的稳健性. 具体来说,如果检测到的 QRS 波峰远高于阈值时,说明阈值设置过低,高阈值基于前面 5 个 QRS 波的波峰,设置为平均值的 0.7 倍,相应的低阈值设置为 0.3 倍. 当波峰处于高阈值与低阈值之间时,保持高阈值不变,调高低阈值,有利于排除不必要的噪声信号. 阈值变化是基于不断变化的 QRS 波具有一定的自适应,自适应阈值调整公式为

$$f_{\max} = \begin{cases} 0.7 \times \text{avg}(R_{b1} + R_{b2} + \dots + R_{b5}), & R > R_{\max}, \\ 0.5 \times R, & R_{\min} < R < R_{\max}, \\ f_{\max}, & R < R_{\min}, \end{cases} \tag{1}$$

$$f_{\min} = \begin{cases} 0.3 \times R_{\text{avg}}, & R > R_{\max}, \\ 0.3 \times R_{\text{avg}} + f_{\min}, & R_{\min} < R < R_{\max}, \\ f_{\min}, & R < R_{\min}. \end{cases} \tag{2}$$

式(1),(2)中: $R$  表示波峰值; $\text{avg}$  表示平均值; $f_{\max}$  为最高阈值; $f_{\min}$  为最低阈值.

心电信号处于不断变换中,每次心拍持续时间和表现波形并不完全一致,很难精准定位每个 P 波和 T 波的起点和终点位置. 整个心拍周期基本在 0.6~0.8 s 之间,而 MIT-BIH 心律失常数据库的采样频率为 360 Hz,故对于一个完整心拍,其采样点长度应该在 216~288 之间. 以 QRS 波为参考位置,分别向前选取 100 个点和向后选取 150 个点,共 250 个点,将其作为一个片段进行分割截取,使其包含完整的心拍.

## 2 基于双向长短期记忆网络的心拍分类

### 2.1 长短期记忆(LSTM)网络

LSTM 网络是 RNN 网络中的一种,由 Hochreiter 等<sup>[16]</sup>提出,相比于经典的 RNN 结构,LSTM 最大的特点就是引入了门的机制和记忆元组,解决了 RNN 网络中存在的梯度消失和梯度爆炸问题. LSTM 与经典的 RNN 结构类似,但 ECG 信号是一维信号,也是一个时间序列,因此,LSTM 非常适合处理心电信号.

LSTM 的门结构主要由遗忘门、输入门和输出门组成,其网络结构,如图 3 所示. LSTM 通过这 3 种门对细胞的状态进行控制与保护. 遗忘门决定删除哪些信息,它接受上一时刻的输出  $h_{t-1}$  与当前时刻的输入  $x_t$ ,接着输出遗忘矩阵  $F_t$ ,从而控制上一时刻的细胞状态  $C_{t-1}$  是否通过.

新的信息传送到细胞的状态中,输入门开始接收  $h_{t-1}$  与  $x_t$ ,接着,tanh 层产生候选状态值并对之前的  $C_{t-1}$  进行迭代更新.  $F_t$  为遗忘矩阵, $C_{t-1}$  为之前时刻的状态, $i_t$  为更新的数值. 输出门决定输出的信息,通过输出门(sigmoid 层)产生一个输出矩阵  $O_t$ ,决定输出目前状态  $C_t$  的结果, $C_t$  状态通过 tanh 层与  $O_t$  做乘积,输出结果  $h_t$ .

LSTM 的更新公式为

$$F_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f), \tag{3}$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i), \tag{4}$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c), \tag{5}$$

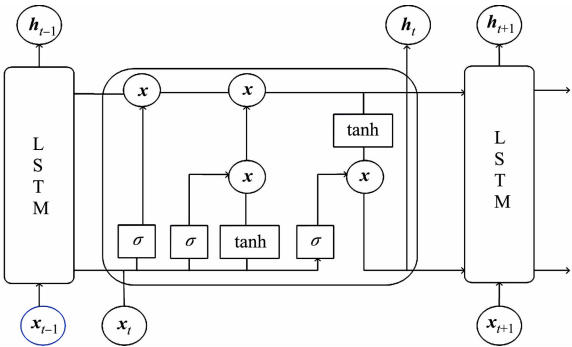


图 3 LSTM 网络结构

Fig. 3 Network structure of LSTM

$$C_t = F_t \times C_{t-1} + i_t \times \tilde{C}_t, \tag{6}$$

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o), \tag{7}$$

$$h_t = O_t \times \tanh C_t. \tag{8}$$

式(3)~(8)中:  $W_f, W_i, W_c, W_o$  为各个门的权重参数;  $b_f, b_i, b_c, b_o$  为偏置参数。

LSTM 对 RNN 进行了改进,使其能获取更长距离的信息元素。但 LSTM 和 RNN 都只是单向推进,会出现后面的因素比前面的因素更重要的情况,这是不够准确的。因此,为了提高心拍分类的准确性,提出基于双向长短期记忆网络的方法。

### 2.2 双向长短期记忆 (BiLSTM) 网络

BiLSTM 由前向 LSTM 与后向 LSTM 组合而成,是 LSTM 的变种和改进<sup>[17]</sup>。改进的 LSTM 进行双向推进,把两个方向的 LSTM 结合起来得到最终的输出  $y_t$ 。BiLSTM 网络结构,如图 4 所示。

给定时间步  $t$  的小批量输入  $x_t$ ,假设该时间步正向隐藏状态为  $\vec{h}_t$ ,反向隐藏状态为  $\overleftarrow{h}_t$ 。分别计算正向隐藏状态和最终输出  $y_t$  状态,即

$$\vec{h}_t = x_t W_{sh}^{(f)} + \vec{h}_{t-1} + W_{hh}^{(f)} + b_h^{(f)}, \tag{9}$$

$$y_t = W_{sh}^{(f)} \vec{h}_t + b_h^{(b)}. \tag{10}$$

式(9),(10)中:权重  $W_{sh}^{(f)}, W_{hh}^{(f)}$  和偏差  $b_h^{(b)}, b_h^{(f)}$  均为模型参数。

采用双向长短期记忆网络,预处理数据后,将单个心拍转变为时间序列输入训练好的网络模型中;分类器输出心拍对应的心律失常类型。基于 BiLSTM 的心拍分类网络结构,如图 5 所示。具体有以下 3 个步骤。

**步骤 1** 心拍信号。为了便于截取和操作,向前选取 100 个点,向后选取 150 个点,共计 250 个点(时间约为 0.7 s)作为一个完整的心拍,即作为时间序列输入  $x$ 。

**步骤 2** 模型结构训练。训练集的完整心拍经过时间序列输入层后,依次进入双向 LSTM 层、全连接层、Softmax 层。双向 LSTM 层由前向层和后向层组成,每个时间步骤结合前向和后向层输出,将前向层和后向层输出连接起来送到 Softmax 层和分类层。

**步骤 3** 心拍检测。将经过专家标注的心拍集作为标签,训练好的模型与测试集用于检测分类效果,与真实标签对比检验文中算法的精准度。

## 3 实验结果与分析

### 3.1 数据来源

MIT-BIH 心率失常数据库是由美国麻省理工学院与贝斯以色列提供的可公开使用的数据库。它包含 48 条 30 min 左右的两导联心电信号记录,分别来自 47 个不同个体(包含 25 名年龄为 32~89 岁的男性和 22 名年龄为 23~89 岁的女性),心电信号的采样频率为 360 Hz<sup>[18]</sup>。

依据 ANSI/AAMI EC57:2012<sup>[19]</sup> 标准,将心拍类型划分为正常或束支传导阻滞(N)、室上性异常(S)、心室异常(V)、融合(F)4 类。N,V,S,F 的心拍数量分别为 90 285,7 140,3 002,800,各类型的心拍数量分布十分不均衡。若把获取的各类型心拍数量直接载入网络进行训练,则网络训练的效果必然出现偏差。为了避免数据不平衡带来的影响,以心拍类型数量最少的 F 类心拍数量为基准,将心拍进行随机排列,分别从 N,V,S,F 中随机选取 10 000,7 000,3 000,800 个样本作为本次分类的数据。在 20 800 个样本中,选取其中 90%作为训练集,其余 10%作为验证集,训练集与测试集数据交叉验证,避免过拟合。

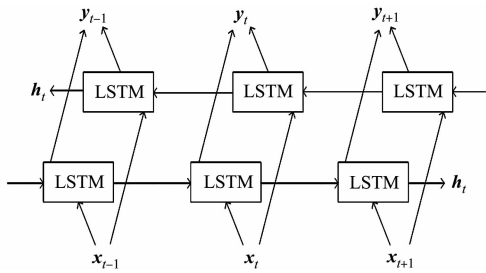


图 4 BiLSTM 网络结构  
Fig. 4 Network structure of BiLSTM

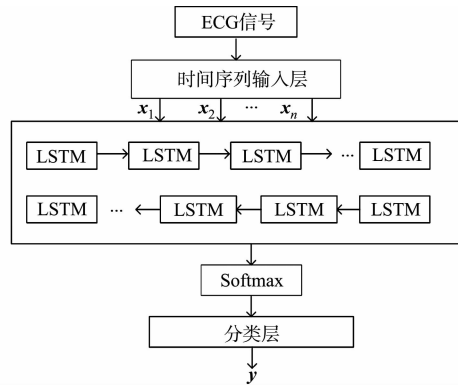


图 5 基于 BiLSTM 的心拍分类网络结构  
Fig. 5 Network structure of heartbeat classification based on BiLSTM

3.2 训练参数及实验平台

训练时采用 Adam 优化算法,与默认随机梯度下降法相比具有更好的适应性,其学习率为 0.001,一次训练所抓取的数据样本数量为 16.

实验平台的硬件为 Intel i5-4200H,显卡为 GEFORCE-GTX850M,内存为 8 GB,操作系统基于 Windows10,编程语言为 Python,深度学习的框架为 Tensorflow,开发工具为 MATLAB2018a.

3.3 评价标准

ECG 心律失常分类效果的评估指标为特异性( $\eta_{spe}$ )、敏感性( $\eta_{sen}$ )和准确率( $\eta_{acc}$ ),这些指标可以通过混淆矩阵呈现.各评估指标的计算式为

$$\eta_{spe} = \frac{TN}{TN+FP} \times 100\%,$$

(11)

$$\eta_{sen} = \frac{TP}{TP+FN} \times 100\%,$$

(12)

$$\eta_{acc} = \frac{TP+TN}{TP+FN+FP+TN} \times 100\%.$$

(13)

式(11)~(13)中:TP,FP,FN,TN 分别为样本真阳性、假阳性、假阴性、真阴性的数量.

3.4 分类效果对比

根据 ANSI/AAMI EC57—2012 中心律失常的评估标准,利用测试集分别检验 CNN,LSTM,BiLSTM 3 种模型算法的泛化能力,并采用混淆矩阵表示实验分类结果.3 种算法对 4 种心律失常类型的分类结果,如表 1 所示.

表 1 3 种算法对 4 种心律失常类型的分类结果  
Tab. 1 Classification results of four arrhythmia types by three algorithms

	CNN 算法的预测值					$\eta_{acc}/\%$	LSTM 算法的预测值				$\eta_{acc}/\%$	BiLSTM 算法的预测值				$\eta_{acc}/\%$
	N	V	S	F	N		V	S	F	N		V	S	F		
真实值	N	937	12	5	0	96.73	955	8	9	1	96.20	958	4	8	2	98.46
	V	8	749	14	0	96.35	25	681	17	4	95.77	5	704	12	4	97.10
	S	9	15	258	0	97.36	32	18	246	2	96.20	11	8	280	1	98.03
	F	34	27	12	0	94.49	4	16	1	61	98.65	2	14	1	66	98.85

由表 1 可知:3 种模型算法对 4 种心律失常类型的心拍识别准确率平均都能到达 94%以上,能够完成分类的任务.

依据统计表和混淆矩阵,输出 4 种心律失常类型的准确度、灵敏性和特异性,将文中基于 BiLSTM 模型的深度学习算法与其他算法的分类效果进行对比,结果如表 2 所示.表 2 中:GMM 为高斯混合模型;HOS 为高斯统计分析;WPE 为小波熵;RF 为随机森林.

表 2 基于 BiLSTM 模型的深度学习算法与其他算法的分类效果对比  
Tab. 2 Comparison of classification effect between deep learning algorithm  
based on BiLSTM model and other algorithms

算法	N		V		S		F		$\eta_{acc}/\%$
	$\eta_{sen}/\%$	$\eta_{spe}/\%$	$\eta_{sen}/\%$	$\eta_{spe}/\%$	$\eta_{sen}/\%$	$\eta_{spe}/\%$	$\eta_{sen}/\%$	$\eta_{spe}/\%$	
GMM+HOS <sup>[20]</sup>	97.37	87.25	95.99	98.07	86.50	99.66	11.86	99.71	96.17
WPE+RF <sup>[21]</sup>	94.67	96.08	94.20	99.29	20.00	96.31	50.00	99.22	94.61
1D-CNN	98.22	95.47	97.15	95.87	91.49	98.28	0	100.00	93.46
LSTM	98.15	94.49	93.67	96.90	82.55	98.48	74.39	99.65	93.41
BiLSTM	98.56	98.38	97.10	98.08	93.33	98.54	79.52	99.65	96.54

由表 2 可知:GMM+HOS 算法的整体准确率虽然达到 96.17%,但其对 F 类敏感性仅有 11.86%,存在数据不平衡的情况.此外,在对心电信号进行特征提取过程中,由于 GMM+HOS 算法的非线性拟合效果受限,通过这种数学方法处理信号时,会损失一些有用的信息,从而对结果产生一定的影响.

WPE+RF 算法虽然整体准确率超过了平均水平,但是对 S,F 类的敏感性仅为 20.00%,50.00%,远低于平均水平,不能满足分类的应用要求.基于数学变换的 WPE 方式使特征的意义不够直观,解释

性也不够强;而 RF 在训练集有噪音时,会出现过拟合的现象,对于特征量不多的数据,分类效果不好.

1D-CNN 算法可以利用局部波形与整体心电信号的关系,将波形的低层次变换特征转换成的高层次特征. CNN 算法的特点得到了很好的利用:局部连接使网络可提取数据的局部特征;权值共享减小了训练的难度;池化操作和多层结构将低层次特征组合为高层次特征. CNN 的滤波器尺寸和数据量不够大,使 CNN 算法的训练难以充分发挥. 从表 2 可以看出,虽然 CNN 算法的总体分类效果不错,对 V 类的敏感性最高为 97.15%,但其对 F 类基本不能识别,而且模型中需要确定的超参数较多,要达到最高的准确率没有具体的规律可循,需要反复实验,耗费大量时间.

GMM+HOS,WPE+RF,1D-CNN 算法虽然能完成基本的分类任务,但不能充分发掘和利用心电信号的时间序列中存在的隐藏规律. 相比而言,LSTM 适用于具有时间特征的心电信号,能够有效提取心电信号的时序特征,利用心电信号前后间的联系,使数据和模型得到更好的结果. 由表 2 可知:LSTM 算法的各项评价指标都不是最高,整体效果也不是最好,但是都能达到平均水平以上,而且没有较大的误差和明显的短板. 可见 LSTM 算法能基本满足分类任务的需求.

BiLSTM 的模型算法是基于 LSTM 的改进,由前向 LSTM 和后向 LSTM 结合而成,在发挥了 LSTM 优点的同时,使数据得到更充分的训练,从而减小误差,提高准确性. 无论在各类型识别准确的数目上,还是在各类型评价指标上,BiLSTM 算法都明显优于 LSTM 算法,说明 BiLSTM 算法的改进是有效的. BiLSTM 算法对 N 类的敏感性、特异性和对 S 类的敏感性分别为 98.56%,98.38%,93.33%,比其他 4 种方法都高;对其他心率失常类型的敏感性和特异性指标也都排在前三位,整体分类准确率也最高,故 BiLSTM 算法的整体综合指标最好. 以上几种分类算法对 S 类的分类效果会略低于 N 类和 V 类,除了选取的样本不够典型造成错误分类外,还因为 S 类心拍与 N 类心拍的形态特征十分相似,波形的重合度很高,造成部分 S 类心拍被错误归类到 N 类,而把异常心拍归为正常 N 类.

3.5 分类速度对比

从分类速度方面看,由于 GMM+HOS,WPE+RF 算法不是基于多层神经网络的模型算法,其计算复杂度远低于基于多层神经网络的算法,故耗时明显低于 1D-CNN,LSTM 和 BiLSTM 算法. 采用 3 种神经网络算法,对 MIT-BIH 心律失常数据库中同样的心电数据进行分类,对比其心拍识别的准确率和耗时结果,如表 3 所示. 表 3 中: $N$  为数据量; $\eta_{acc}$  为准确率; $t$  为时间.

由表 3 可知:基于 BiLSTM 模型算法虽然耗时多于单向的记忆网络算法,但能够明显提高准确率.

表 3 基于神经网络模型算法的分类速度比较  
Tab. 3 Comparison of classification speed based on neural network model algorithm

算法	$N$ /个	$\eta_{acc}/\%$	$t/s$
1D-CNN	20 800	93.46	149.80
LSTM	20 800	93.41	3 660.17
BiLSTM	20 800	96.54	7 214.87

4 结束语

基于双向长短期记忆模型的深度学习算法,在 MIT-BIH 心律失常数据库下进行分类识别时,整体的准确率达到 96.54%,相比于其他几种模型算法具有明显优势. 但深度学习的训练往往基于大量的数据输入,而选择的 MIT-BIH 心律失常数据库的数据有限且心律失常样本内部的数据不平衡,使训练时分类结果容易往数据量大的类型偏移,对分类结果会有一定的影响. 在接下来的研究中,可以尝试扩充增强数据量,减少数据不平衡带来的影响,尽可能提高模型的泛化能力,使文中算法能有效地应用于其他数据上.

参考文献:

[1] 胡盛寿,高润,刘力生,等.《中国心血管病报告 2018》概要[J]. 中国循环杂志,2019,34(3):209-220. DOI:10.3969/j.issn.1000-3614.2019.03.001.

[2] 陈伟伟,高润霖,刘力生,等.《中国心血管病报告 2017》概要[J]. 中国循环杂志,2018,33(1). DOI:10.3969/j.issn.1000-3614.2018.01.001.

[3] VIMAL C,SATHISH B. Random forest classifier based ECG arrhythmia classification[J]. International Journal of Healthcare Information Systems and Informatics,2009,5(2):1-10. DOI:10.4018/jhisi.2010040101.

[4] LANATÁ A,VALENZA G,MANCUSO C,et al. Robust multiple cardiac arrhythmia detection through bispectrum

- analysis[J]. *Expert Systems with Applications*, 2011, 38(6): 6798-6804. DOI: 10.1016/j.eswa.2010.12.066.
- [5] YE H Y C, CHIOU C W, LIN H J. Analyzing ECG for cardiac arrhythmia using cluster analysis[J]. *Expert Systems with Applications*, 2012, 39(1): 1000-1010. DOI: 10.1016/j.eswa.2011.07.101.
- [6] GOMES P R, SOARES F O, CORREIA J H, *et al.* ECG Data-Acquisition and classification system by using wavelet-domain Hidden Markov Models[C]// *Annual International Conference of the IEEE Engineering in Medicine and Biology*. Buenos Aires: IEEE Press, 2010: 4670-4673. DOI: 10.1109/IEMBS.2010.5626456.
- [7] ZUBAIR M, KIM J, YOON C. An automated ECG beat classification system using convolutional neural networks [C]// *6th International Conference on IT Convergence and Security*. Prague: IEEE Press, 2016: 1-5. DOI: 10.1109/ICITCS.2016.7740310.
- [8] KIRANYAZ S, INCE T, HAMILA R, *et al.* Convolutional neural networks for patient-specific ECG classification [C]// *37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. Milan: IEEE Press, 2015: 2608-2611. DOI: 10.1109/EMBC.2015.7318926.
- [9] AL RAHHAL M M, BAZI Y, ALHICHRI H, *et al.* Deep learning approach for active classification of electrocardiogram signals[J]. *Information Sciences*, 2016, 345(1): 340-354. DOI: 10.1016/j.ins.2016.01.082.
- [10] ZHANG Chenshuang, WANG Guijin, ZHAO Jingwei, *et al.* Patient-specific ECG classification based on recurrent neural networks and clustering technique[C]// *13th IASTED International Conference on Biomedical Engineering*. Innsbruck: IEEE Press, 2017: 63-67. DOI: 10.2316/P.2017.852-029.
- [11] EBRAHIMZADEH E, MANUCHEHRI M S, AMOOZEGAR S, *et al.* A time local subset feature selection for prediction of sudden cardiac death from ECG signal[J]. *Medical and Biological Engineering and Computing*, 2018, 56(7): 1253-1270. DOI: 10.1007/s11517-017-1764-1.
- [12] WANG Yichao, DEEPU C J, LIAN Y. A computationally efficient QRS detection algorithm for wearable ECG sensors[C]// *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. Boston: IEEE Press, 2011: 5641-5644. DOI: 10.1109/IEMBS.2011.6091365.
- [13] 王吉鸣, 吕颖莹, 包涛, 等. 动态心电图监测系统介绍及关键技术水平分析[J]. *中国医疗设备*, 2016, 31(10): 71-74. DOI: 10.3969/j.issn.1674-1633.2016.10.021.
- [14] 赵羿欧, 刘扬. 一种改进的差分阈值心电图检测算法[J]. *计算机工程*, 2011(增刊 1): 347-348.
- [15] 梁小龙. 基于 CNN 和 LSTM 结合的心律失常分类研究[D]. 重庆: 西南大学, 2019.
- [16] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780. DOI: 10.1162/neco.1997.9.8.1735.
- [17] GONZÁLEZ AV, HANSEN VPB, BINGEL J, *et al.* Coastal at semeval-2019 task 3: Affect classification in dialogue using attentive bilstms[C]// *Proceedings of the 13th International Workshop on Semantic Evaluation*. Minneapolis: [s. n.], 2019: 169-174. DOI: 10.18653/v1/S19-2026.
- [18] MOODY G B, MARK R G. The impact of the MIT-BIH arrhythmia database. [J]. *IEEE Engineering in Medicine and Biology Magazine*, 2002, 20(3): 45-50. DOI: 10.1109/51.932724.
- [19] Association for the Advancement of Medical Instrumentation. Testing and reporting performance results of cardiac rhythm and ST segment measurement algorithms: ANSI/AAMI EC57: 2012[S]. Arlington: American National Standard, 2013.
- [20] AFKHAMI R G, AZARNIA G, TINATI M A. Cardiac arrhythmia classification using statistical and mixture modeling features of ECG signals[J]. *Pattern Recognition Letters*, 2016, 70: 45-51. DOI: 10.1016/j.patrec.2015.11.018.
- [21] LI Taiyong, ZHOU Min. ECG classification using wavelet packet entropy and random forests[J]. *Entropy*, 2016, 18(8): 285. DOI: 10.3390/e18080285.

(责任编辑: 黄晓楠 英文审校: 吴逢铁)