

混合深度学习机制下的H型高血压脉诊预测

杨晶东¹, 陈磊¹, 蔡书琛¹, 解天晓², 燕海霞²

(1. 上海理工大学光电信息与计算机工程学院, 上海 200093; 2. 上海中医药大学基础医学院, 上海 201203)

摘要: 现有H型高血压诊断需要检测患者体内的伴有血浆同型半胱氨酸含量, 效率低且带有创口。中医学脉诊可以通过分析患者脉搏生理活动, 结合临床问诊信息实现H型高血压无创辅助诊断。本文提出了基于混合深度学习的脉诊分类模型, 在具有双向长短期记忆(Bi-directional long short-term memory, BiLSTM)网络中增加卷积神经网络(Convolutional neural network, CNN)结构提取脉诊特征局部相关特征, 构建基于CNN-BiLSTM结构的高血压脉诊分类网络。实验采用上海中医药大学附属龙华医院及中西医结合医院的325例临床疑似高血压脉诊病例。实验结果表明本文模型评估参数灵敏度、特异性、正确率、 F_1 -score、接收者操作特征(Receiver operating characteristic, ROC)曲线及其下方围成的面积(Area under curve, AUC)值分别为: 79.71%、69.56%、77.17%、83.96%、0.850 0, 高于经典机器学习方法的诊断精度, 对中医临床辅助诊断具有较好的参考价值。

关键词: H型高血压; 混合深度学习; 双向长短期记忆网络; 卷积神经网络

中图分类号: TP181 **文献标志码:** A

Prediction on Pulse-Taking for H-type Hypertension Under Hybrid Deep Learning Mechanism

YANG Jingdong¹, CHEN Lei¹, CAI Shuchen¹, XIE Tianxiao², YAN Haixia²

(1. School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China; 2. Basic Medical College, Shanghai University of Traditional Chinese Medicine, Shanghai 201203, China)

Abstract: The diagnosis of H-type hypertension requires the determination of the patient's plasma homocysteine content, which is inefficient and has a wound. Chinese pulse diagnosis helps doctors diagnose H-type hypertension by analyzing patient's pulse activity and combining inquiry information. Therefore, we put forward a pulse-taking diagnosis classification model based on hybrid deep learning model, which can extract the local features via convolutional neural network (CNN) block, and long-term dependency features via Bi-directional long short-term memory (BiLSTM) block. The data come from 325 suspected cases of pulse diagnosis collected by Longhua Hospital affiliated to Shanghai University of Chinese Medicine and Hospital of Integrated Traditional Chinese and Western Medicine. We compare the proposed model with other machine learning models on the pulse diagnosis data respectively. The sensitivity, specificity, accuracy, F_1 -score, receiver operating characteristic (ROC) area under curve (AUC) values of the proposed model are 79.71%, 69.56%, 77.17%, 83.96%, 0.850 0, respectively, higher than the performance of other machine learning models. The results show that our model has good performance and has good reference value for the clinical diagnosis of traditional Chinese medicine.

Key words: H-type hypertension; hybrid deep learning; bi-directional long short-term (BiLSTM) network; convolutional neural network(CNN)

引 言

近些年来,高血压患病率逐步攀升。血浆同型半胱氨酸(Homocysteine, HCY)水平大于 $10 \mu\text{mol/L}$ 的高血压被定义为“H型”高血压,在高血压患者中高达 75% 为 H 型高血压。HCY 水平升高是冠状动脉粥样硬化性心脏病、脑卒中等心脑血管疾病的危险因素^[1]。研究证实 HCY 水平与心血管疾病的发生具有正相关性, Graham 等^[2]发现,单独存在高血压或 HCY 水平升高的患者中,脑卒中死亡风险分别为正常人的 3.6 倍和 4.2 倍,而高血压与 HCY 水平同时升高的患者脑卒中死亡的风险则增加至 12.1 倍。迄今为止,检测血液中的 HCY 含量多少是临床诊断 H 型高血压的唯一途径^[3]。

随着深度学习和机器学习应用到中医领域进行相关研究,中医知识的碎片性和经验性不再是难题。随机森林算法具有较高训练速度,可以对内部泛化误差进行无偏估计。同时随机森林算法引入了重采样和属性选择的随机性,对噪声不敏感,克服了过拟合问题。因此出现了将集成随机森林应用于肺结节的良恶性分类。借鉴深度学习思想,出现了深度随机森林算法^[4],应用于慢性胃炎的中医症候分类,为慢性胃炎诊断提供依据。Zhang 等^[5]采用 9 层卷积神经网络(Convolutional neural network, CNN)对脉搏波进行分类,平均准确率达到 93.49%。文献[6]提出一种改进的 CNN 模型对脉搏波分类,在不同的数据集上最高分类精度达到 95%; Ouyang 等^[7]采用 CNN 模型对 II 型糖尿病患者的脉搏波分类,最高精度可达到 90.6%,但当 CNN 层数较深时,才能提取到脉搏波深层特征,容易造成梯度消失问题。张选等^[8]基于 GoogleNet 和 ResNet 框架提出 MIRNet 模型对健康和亚健康人群脉象分类,精度可达到 87.84%。Chen 等^[9]采用基于 BasicBlocks 的 ResNet 框架 BRNet 模型对女性脉搏波分类,判断是否处在妊娠期,预测准确率达到 89%,接收者操作特征(Receiver operating characteristic, ROC)曲线及其下方围成的面积(Area under curve, AUC)值为 0.91。虽然这些方法一定程度上解决了梯度消失问题,但模型深度多数处在 4~6 层,无法学习到脉搏波周期内的深度时序特征。杨浩等^[10]运用卷积和双向长短时记忆(Bi-directional long short-term memory, BiLSTM)融合网络对心房节拍分类,精度可达到 90.21%。马明艳等^[11]使用 CNN-BiLSTM 网络对入侵的恶意行为进行检测,精度达到了 92%。该方法在 CNN 和 BiLSTM 基础上进行融合,均具有“并联”多通道融合特性,当数据时序较长时, BiLSTM 模型训练时间较长,出现特征冗余问题。本文提出一种异质集成混合深度学习模型,采用 CNN 结构提取脉搏波浅层特征,同时“串联”BiLSTM 结构学习脉搏波的深层时序特征以及数据在时间序列上的相关性^[12]。该模型可以根据患者脉诊信息实现对 H 型高血压患者自主分类,为 H 型高血压患者诊断提供了新思路。

1 混合深度学习网络模型

CNN 由输入层、卷积层、池化层、全连接层和输出层构成。卷积层和池化层数量根据输入需要调整,一般采用卷积层和池化层交替设置^[13]。CNN 采用了局部连接和共享权值方式。减少了网络权值数量,降低了过拟合风险。循环神经网络(Recurrent neural network, RNN)可以学习任意具有序列特征的神经网络。当输入维度增多, RNN 对较早时间的一些节点的感知力下降,难以学习到长时间序列特征,而产生依赖问题,从而发生梯度消失或者梯度爆炸现象。长短时记忆(Long short-term memory, LSTM)^[14-15]网络是一种特殊 RNN 网络,其核心是利用“记忆细胞”记住长期的历史信息,采用门机制管理,门结构不提供信息,仅用来限制信息量,是一种多层次特征选择方式。LSTM 解决了 RNN 梯度爆

炸和消失的问题,使模型能够学习到长时间序列的特征。忘记门、输入门、输出门和记忆细胞以及相应的更新公式分别为

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

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \tag{2}$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \tag{3}$$

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \tag{4}$$

$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o) \tag{5}$$

$$h_t = o_t \times \tanh(C_t) \tag{6}$$

式中: f_t 为遗忘门; i_t, \tilde{C}_t, o_t 为更新门; h_t 为输出门; W 为权重; b 为偏置。

但传统 LSTM 只能学习序列单向信息,如图 1(a)所示, BiLSTM^[16-17] 网络结构在每一个训练序列的前后同层各连接一个单向 LSTM, 可从正、反两方向提取特征, 提高模型分类精度。 BiLSTM 模型结构如图 1(b)所示。图 1(a)中 σ 为 Sigmoid 函数, 它的输出在 0~1 之间, tanh 为双曲正切函数, 输出在 -1~1 之间, $c\langle t \rangle$ 为记忆细胞状态, $h\langle t \rangle$ 为隐含层状态。图 1(b)中 X 表示输入, Y 表示输出, A 表示隐藏层。

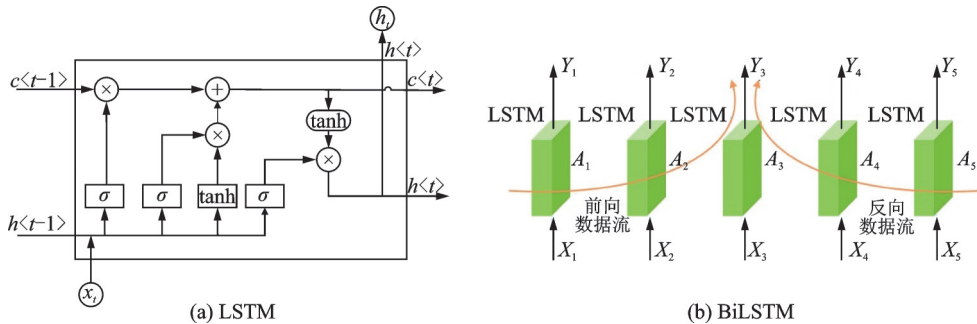


图 1 LSTM 及 BiLSTM 体系结构图

Fig.1 Architecture diagrams of LSTM and BiLSTM

临床中医脉搏波数据呈现一维特性,采用一维卷积提取特征,会减少脉搏波特征间的相关性。针对脉搏波的时间特性,本文采用 CNN 提取脉搏波局部特征,并采用 BiLSTM 获取各特征间时序关系,构建基于 CNN-BiLSTM 异质混合深度学习方法,结构图如图 2 所示,本文提出的 H 型高血压预测算法步骤为:

- (1) Input: X_i, Y_j , where $i, j = 1, 2, \dots, n$, number of CNN block layer a , number of BiLSTM block layer b , weight W
- (2) for $i = 1, 2, \dots, n$ do
- (3) $C_i = w_i \times x_i$ #Convolution
- (4) $M_i = \text{Max}(C_{i,k}, C_{i,k+1}, C_{i,k+2}, \dots, C_{i,k+l})$ where $k, l = 1, 2, \dots, n$ #Maxpooling
- (5) $B_i = a_i \times M_i + b_i$
- (6) $F_i = \text{Flatten}(B_i)$
- (7) Output: $P_i = W_i \times F_i$
- (8) end for

2 材料与方法

2.1 样本分布

脉诊的脉搏波数据由脉诊仪采集,样本采集前,患者需要放松 5 min 以上,采样时间为 60 s,采样触点压力依患者脉络深浅确定,采样频率包括 200、700、1 000 Hz。问诊样本根据门诊医师询问患者相关基础病症状况构建量表数据,为问诊分析提供依据。本文采用上海中医药大学附属龙华医院及中西医结合医院所提供的临床脉诊及问诊数据。共 325 例脉诊。男性病例 138 例(42.31%),平均年龄(66.35±10.37)岁;女性病例 187 例(57.69%),平均年龄(71.32±8.51)岁。H 型高血压患者 125 例,占总病例 38.19%,非 H 型高血压患者 200 例占总病例 61.81%。病例分布如图 3 所示。

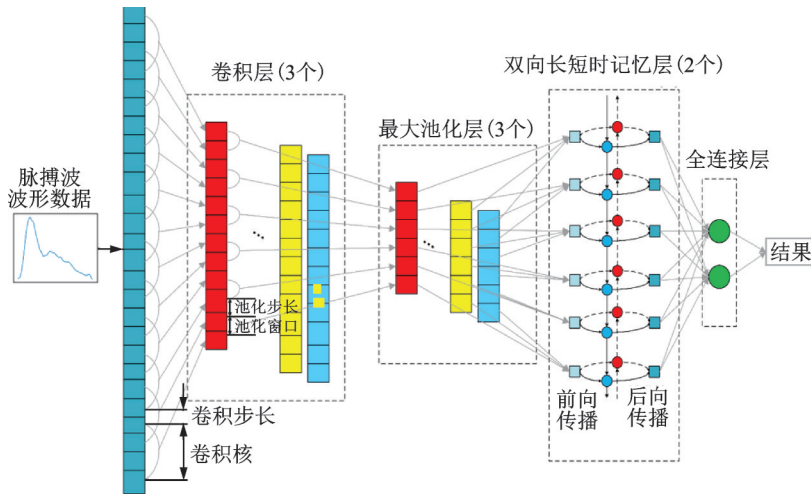


图 2 混合卷积双向长短时记忆网络结构图

Fig.2 CNN-BiLSTM architecture diagram

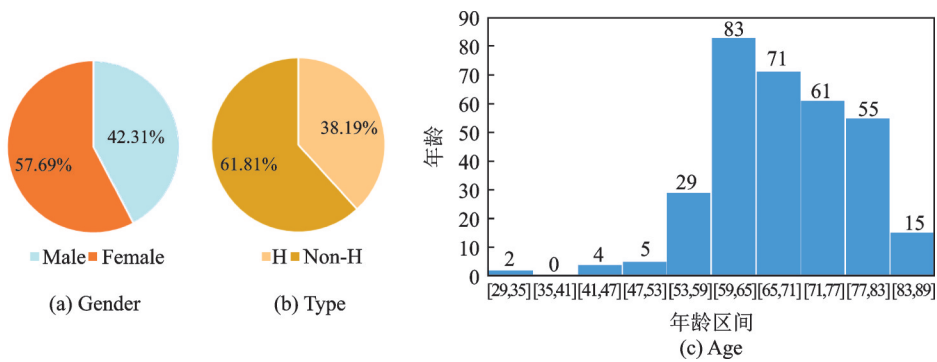


图 3 脉诊样本分布

Fig.3 Description of samples on pulse-taking diagnosis

2.2 脉诊数据预处理

脉诊采样频率包括 200、700、1 000 Hz 三种,为了保证数据集维度一致性,将 1 000、700 Hz 降采样为 200 Hz。由于脉搏信号很容易受到干扰而引入高频噪声,严重干扰脉搏信号特征提取,甚至导致脉搏波波形突变。为此,本文对原始脉搏波信号进行降噪、去除高频噪声等操作。传统傅里叶变换是一种频域信号分析方法,很难确定在某个时间点上的具体信号变化,无法分辨信号在时间轴上的突变点。

而小波变换具有正交性、方向选择性、可变的时频域分辨率等特点,可以有效提取脉搏波信号关联特征。本文选择Symlets系列中的Sym7小波作为小波基对脉象信号进行降噪处理^[18]。由于脉搏信号的绝大部分能量都集中在0~15 Hz之间,降采样处理后,脉搏波频率皆为200 Hz,因此设置9层脉搏波分解作为默认阈值。被采集者的呼吸和体动会引起脉象信号波动,使脉搏波形变失真,引起脉搏波基线漂移^[19],因此必须对脉搏信号进行预处理,去除存在的脉搏波基线漂移^[20]。常用的基线漂移去除方法包括小波变换(Wavelet transform, WT)^[21]、经验模态分解(Empirical mode decomposition, EMD)^[22-23]以及平滑先验法(Smoothness priors approach, SPA)^[24-25],由于脉诊波形频率不同,自适应小波级联方法需要多次调整小波分解系数。平滑先验法通过调节平滑参数λ实现频率响应,简便易行。因此,本文采用平滑先验法去除脉搏波基线漂移

$$p = \left(I - (I + \lambda^2 D_2^T D_2)^{-1} \right) y \tag{7}$$

式中: p 为有效脉搏波信号; I 为观测矩阵的单位矩阵; D_2 为二阶微分矩阵; y 为原始信号。

通过选择不同的正则化参数可以得到不同的滤波特性。脉搏波信号中基线漂移的频率为0.2~0.3 Hz,脉搏波的采样频率为200 Hz,因此在该采样频率下,取λ=2 500 对应截止频率为200×0.002 5 Hz=0.5 Hz,可以有效去除脉搏波信号中低于0.5 Hz的基线漂移信号。脉搏波样本采集时间为60 s,包含多个完整周期,对脉搏波样本截取,使所有样本单周期内数据点少于250,提取400个数据点,偏移量为100个数据点,保证每段数据均包含一段完整周期^[26-27]。因此,每个样本至少能扩展成114个包含一个完整周期的波形。本文采用评估参数信噪比(Signal noise ratio, SNR)和均方根误差(Root mean square error, RMSE)评估脉搏波去除基线漂移后效果。SNR值越大, RMSE值越小,说明去噪效果越好,表达式为

$$SNR = 10 \lg \left(\frac{\sum_{n=1}^N p^2(n)}{\sum_{n=1}^N [p'(n) - p(n)]^2} \right) \tag{8}$$

$$RMSE = \sqrt{\frac{\sum_{n=1}^N [p'(n) - p(n)]^2}{N}} \tag{9}$$

式中: $p'(n)$ 为原始信号; $p(n)$ 为去基线漂移后信号; N 为信号长度。

3 实验结果

3.1 模型超参数设置

CNN-BiLSTM模型超参数设置如表1所示,对于脉诊数据,前3层为CNN层,卷积核数目分别为32、64、128,卷积核长度为3、3、2,步长均为1,各层间添加3层最大池化层,核长为3、2、2,步长全为1。后两层采用BiLSTM模型层,神经元数为32,最后采用全连接层输出分类结果。

表1 CNN-BiLSTM模型超参数
Table 1 Hyper parameters of CNN-BiLSTM model

Layer	Filter size	Output shape (Depth × Width)
Input		1 × 400
Convolutional layer 1	3 × 32, Stride=1	32 × 398
MaxPooling 1	3 × 1, Stride=1	32 × 133
Convolutional layer 2	3 × 64, Stride=1	64 × 131
MaxPooling 2	2 × 1, Stride=1	64 × 66
Convolutional layer 3	3 × 128, Stride=1	128 × 64
MaxPooling 3	2 × 1, Stride=1	128 × 32
BiLSTM 1	Units = 32	32 × 128 × 32
BiLSTM 2	Units = 32	32 × 128 × 32
Flatten		1 × 131 072
Fully connected layer + Sigmoid		2 × 1

3.2 性能评价标准

本文采用5个二分类算法指标和接收者操作特征(Receiver operating characteristic, ROC)曲线及其下方围成的面积(Area under curve, AUC)和精度-召回率(Precision-Recall, PR)曲线及其下方围成的面积平均精度(Average precision, AP)来评价算法性能,包括:灵敏度(Sensitivity, Sen),特异性(Specificity, Spe),准确度(Accuracy, Acc),精确率(Precision, Pre)和 F_1 分数(F_1 -score),表达式为

$$Sen = \frac{TP}{TP + FN} \tag{10}$$

$$Spe = \frac{TN}{TN + FP} \tag{11}$$

$$Acc = \frac{TP + TN}{TP + TN + FN + FP} \tag{12}$$

$$Pre = \frac{TP}{TP + FP} \tag{13}$$

$$F_1\text{-score} = \frac{2 \times Pre \times Sen}{Pre + Sen} \tag{14}$$

式中:真阳性(True positive, TP)表示将样本中H型高血压正确分类为H型高血压的样本数;假阳性(False positive, FP)表示将样本中非H型高血压分类为H型高血压的样本数;真阴性(True negative, TN)表示将样本中非H型高血压正确分类为非H型高血压的样本数;假阴性(False negative, FN)表示将样本中H型高血压分类为非H型高血压的样本数。

3.3 脉诊波形预处理

为了比较各种低频噪声方法,本文采用不同小波阶数、基函数进行对比实验。图4给出了当小波阶数为 N ,小波基为db、Sym和Coif时,脉搏波信噪比SNR和均方根误差RMSE对比情况。表2给出了不同小波基、不同阶数评估参数SNR和RMSE值。分析可知,Sym7小波的SNR最大,为45.5407;RMSE最小,为0.03723。因此,Sym7作为小波去噪的小波基最为适合。这是由于Symles小波系列Sym小波相比db小波和coif小波具有更好的对称性,可以有效减少脉搏波信号重构时的相位失真和噪声。当Sym7小波基的支撑范围为13,消失矩为7时,对于脉搏波能具备较好的正则性,可以较好地集中脉搏波能量,减少边界效应问题。




图4 不同小波去噪效果比较

Fig.4 Comparison of denoising effect of different wavelets

表2 不同小波去噪效果比较

Table 2 Comparison of denoising effect of different wavelets

N	db		Sym		Coif	
	SNR	RMSE	SNR	RMSE	SNR	RMSE
1	29.690 8	0.230 89	29.690 8	0.230 89	43.535 1	0.046 79
2	43.357 5	0.047 87	43.357 5	0.047 87	45.487 1	0.037 46
3	45.254 8	0.038 47	45.254 8	0.038 47	45.538 8	0.037 84
4	45.482 6	0.037 48	45.489 1	0.037 48	45.537 6	0.037 24
5	45.510 1	0.037 36	45.511 5	0.037 35	45.534 1	0.037 26
6	45.505 6	0.037 38	45.530 8	0.037 27		
7	45.512 9	0.037 35	45.540 7	0.037 23		
8	45.517 6	0.037 35	45.539	0.037 28		
9	45.513 0	0.037 35	45.528 7	0.037 23		
10	45.516 8	0.037 33	45.533 6	0.037 26		

图5给出了基线漂移去除3种典型方法评估指标对比,分析可知,对于H型高血压样本,与WT、EMD方法相比,SPA方法保留了脉搏波本征模式特征,剔除了残余稳态量,具有较高的SNR值和较小的RMSE值,说明SPA方法更适合作为脉搏波数据去除的基线漂移方法。

原始脉搏波图像经过去除噪声、基线漂移后的波形图像如图6所示。分析可知,经过去噪、基线漂移后,脉搏波震动幅值和均值均有所降低,其中,基线漂移后波形幅值减少12.25%。同时,脉搏波减少了低频噪声和极端噪点,波形趋于稳定,具有较好的周期性和可区分性。




图5 基线漂移剔除方法比较

Fig.5 Comparison of different baseline shifting methods




图6 去除噪声、基线漂移后的数据波形图

Fig.6 Pulse waves before and after denoising and baseline drift correction

3.4 分类性能评估

图7显示了不同的卷积层和双向长短时记忆层(即模型的深度)对模型性能的影响。可以看出,当卷积层数为3,双向长短时记忆层数为2时,准确度最高。同时AUC值也最高。将该模型参数作为集成脉诊模型参数。当模型层数较少时,模型各项评价指标均较差,无法学习到样本的深层特征,因而准确度较低。而随着模型深度加深,准确度逐渐提高,但容易导致模型过拟合,降低了模型准确度,因此需要做出折中选择。




图7 模型不同深度的性能比较

Fig.7 Performance comparison of models at different depths

针对脉诊数据集,本文采用融合CNN-BiLSTM模型,与CNN和BiLSTM模型进行对比,进行5折交叉验证,表3给出了各模型H型高血压患者分类评价指标。分析可知,CNN-BiLSTM模型综合指标高于其他几种模型,与CNN模型和BiLSTM模型相比, F_1 -score分别增加了9.45%和5.41%,AUC值分别增加了5.45%和7.27%。这是由于与CNN模型相比,CNN-BiLSTM模型增加了BiLSTM模型,可以有效检测具有长依赖关系的脉诊序列波形特征,有利于波形相关性特征提取。与BiLSTM模型相比,CNN-BiLSTM模型增加了CNN模型,可以提取具有局部关联关系的脉诊特征。由于CNN模型共享卷积核,可以有效提高模型分类速度和准确度。典型机器学习模型如随机森林(Random forest, RF)、梯度提升树(Gradient boosting decision tree, GBDT)无法学习H型高血压脉诊波形序列的深层特征,将大多数样本判断为负类,少数样本判断为正类,导致精度偏高,灵敏度、特异性偏低。而深度学习模型BRNet虽然采用了ResNet基本架构,但精度比CNN-BiLSTM降低了3.28%,这是由于脉搏波的时序特征是深层特征,BRNet模型的深度较浅,无法学习到所有的脉搏波特征信息。MIRNet模型在ResNet模块的基础上加入Inception模块,模型深度较深,平均精度比CNN-BiLSTM模型降低了0.44%,可达到0.8055。但模型深度较深,稳定性变差,当数据在尺度上缩放时容易降低模型泛化性能。而脉搏波数据具有周期性,不同周期之间的尺度在预处理后仍具有一

定的差异性,使MIRNet模型评价指标波动较大。因此,对于H型高血压样本,CNN-BiLSTM模型具有较高的分类精度和较好的泛化性能。

表3 脉诊各算法评价指标比较

Table 3 Comparison of evaluation indexes of pulse diagnosis algorithms

Method	Sen	Spe	Pre	F_1 -score	Acc
RF	61.25 ± 7.25	75.00 ± 10.95	94.23 ± 5.78	74.24 ± 5.01	63.04 ± 6.70
GBDT	56.67 ± 0.61	50.00 ± 3.65	98.07 ± 1.55	71.83 ± 1.42	56.52 ± 1.57
CNN	77.55 ± 1.85	65.11 ± 4.03	71.69 ± 1.91	74.51 ± 1.14	71.73 ± 1.59
BiLSTM	73.82 ± 2.40	65.94 ± 6.53	83.93 ± 8.96	78.55 ± 6.60	71.51 ± 5.79
BRNet	74.78 ± 3.18	68.44 ± 5.54	79.98 ± 3.78	76.25 ± 1.69	73.89 ± 2.21
MIRNet	77.86 ± 6.53	66.43 ± 9.20	85.15 ± 6.49	79.08 ± 2.69	76.73 ± 3.82
CNN-BiLSTM	79.71 ± 3.09	69.56 ± 6.38	88.70 ± 4.85	83.96 ± 1.45	77.17 ± 1.61

图8(a)给出了针对脉诊波形样本,各种模型ROC曲线对比。可以看出,相比单模型,CNN-BiLSTM模型ROC曲线位于坐标平面左上部,与横轴所围面积AUC值最大,达到了0.85,比CNN模型提升了5.05%,比BiLSTM模型提升了7.27%。这是由于在较浅层模型下,单层网络无法学习到脉搏波全部特征。CNN-BiLSTM模型比RF提高了14.71%,比GBDT提升了15.53%,这是由于机器学习方法具有数据平衡敏感性,使预测结果偏向多数类非H型高血压。CNN-BiLSTM模型比BRNet和MIRNet提升了3.08%,这是由于BRNet采用浅层ResNet网络,无法提取深层特征。而MIRNet模型层数过深,泛化性能较差。图8(b)给出了针对脉诊波形样本,各种模型的P-R曲线。可以看出,CNN-BiLSTM模型P-R曲线位于坐标平面右侧与横轴包围的面积最大,AP值达到了0.779。相比单模型CNN、BiLSTM模型AP值分别提升了4.77%、20.06%。这是由于CNN模型深度较浅,无法学习脉搏波的深度时序特征,BiLSTM模型受数据维度和周期重复分割的影响下,泛化性能差,AP值较低。相比BRNet和MIRNet,AP值分别提升了7.74%和0.82%。这也体现了CNN-BiLSTM模型具有更好的泛化性能。因此,CNN-BiLSTM模型对于类别不均衡的H型高血压脉搏波样本分类具有更好的分类性能。

表4给出了不同模型运行一个Epoch的时间及模型参数量,典型集成学习模型如RF和GBRT,时

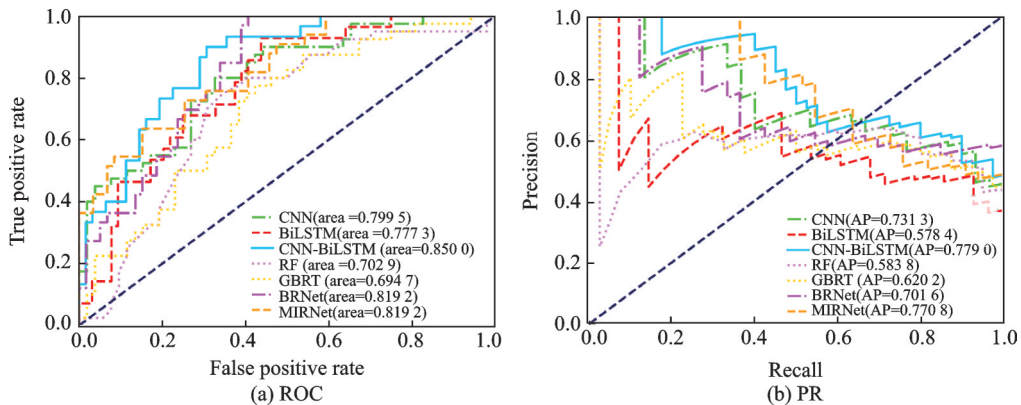


图8 不同算法脉诊分类曲线比较

Fig.8 Comparison of the classification curves of different algorithms in pulse-taking

间复杂度和样本数量、特征维度以及基分类器的种类数量具有较强的相关性,当样本数量增加时,运行时间会急剧增加。对于高血压数据集,CNN-BiLSTM模型训练周期高于CNN、BRNet算法。CNN-BiLSTM模型中CNN模块同时具有特征提取和降维作用,也减少了BiLSTM层的运行时间,提高模型的分性能。MIRNet模型具有较深层数,参数量较大,虽具有较好的分类性能,但运行时间较长,当数据集增大时运行时间将会进一步增加。综合来看,CNN-BiLSTM模型具有较好的时间复杂度与分类性能平衡效果。

表4 不同模型参数量和运行时间
Table 4 Number different model of parameters and runtime

Method	Number of parameters	Time/s
RF		95.6
GBDT		271.4
CNN	34 402	7.1
BiLSTM	84 738	135.0
BRNet	114 418	5.6
MIRNet	7097 218	156.5
CNN-BiLSTM	98 658	11.2

4 实验分析与讨论

本文针对脉诊的脉图特征参数进行分析,并给出特征贡献率排名,如图9所示。脉图参数特征贡献率排名前4位的特征分别为W1/T、H4/H1、H4、 t_1/t_4 ,均大于5%。W1/T表示主动脉压力升高的持续时间,与重搏前波的出现时间和外周阻力有关。H4/H1主要反映外周阻力高低。当外周血管收缩时,阻力增高,H4/H1升高(>0.45);反之,外周阻力降低时,H4/H1变小(<0.30)。H4是降中峡幅度,表示降中峡谷底到脉搏波图基线的高度。降中峡高度与舒张压相对应,与动脉血管外周阻力、主动脉瓣关闭功能有关。前3位特征贡献率都反映了H型高血压患者的血管外周阻力对分类影响,也体现出H型高血压是动脉粥样硬化与动脉硬化的独立危险因素。 t_1/t_4 与心脏射血功能有关, t_1/t_4 值越大,反映心脏急性射血期速度越慢,左心收缩功能减弱, t_4 为左心室收缩期时间。反映了H型高血压患者心脏急性射血期速度与左心收缩功能。其余特征占比如图9所示。

本文通过脉诊各评估参数特征贡献率分析,深入挖掘潜在的脉诊特征因素与H型高血压分类相关性,可有效地提高临床辅助诊断的客观性和准确性。

5 结束语

针对中医学脉诊脉搏波样本,本文根据脉诊数据提出了一种混合深度学习分类模型,该模型可以有效地提取脉诊局部及全局序列特征,从而提高H型高血压的脉诊分类精度。实验结果表明,与传统机器学习相比,该模型具有较好分类精度和泛化性能,其中,灵敏度、特异性、正确率、 F_1 -score、AUC值分别达到79.71%、69.56%、77.17%、83.96%、0.8500。该模型能有效地兼顾H型高血压患者脉诊综合特征,对临床诊断具有较好的参考价值。

参考文献:

[1] 张岩,霍勇.伴同型半胱氨酸升高的高血压“H型”高血压[J].心血管病学进展,2011,32(1): 3-6.
ZHANG Yan, HUO Yong. Hypertension with elevated homocysteine-H type hypertension[J]. Advances in Cardiovascular Dis-




图9 脉诊特征贡献率排名

Fig.9 Feature importance ranking of pulse-taking

- eases, 2011, 32(1): 3-6.
- [2] GRAHAM I M, DALY L E, REFSUM H M, et al. Plasma homocysteine as a risk factor for vascular disease[J]. The European Concerted Action Project JAMA, 1997, 277(22): 1775-1781.
- [3] 周超飞, 郭毅, 邓珏琳. H型高血压与心房颤动的关系研究进展[J]. 心血管病学进展, 2019, 40(9): 1205-1207.
ZHOU Chaofei, GUO Yi, DENG Juelin. H-type hypertension and atrial fibrillation[J]. Advances in Cardiovascular Diseases, 2019, 40(9): 1205-1207.
- [4] 胡会会, 龚敬, 聂生东. 基于集成随机森林模型的肺结节良恶性分类[J]. 计算机应用研究, 2018, 35(10): 3117-3125.
HU Huihui, GONG Jing, NIE Shengdong. Classification of benign and malignant pulmonary nodules based on ensemble random forests[J]. Application Research of Computers, 2018, 35(10): 3117-3125.
- [5] ZHANG S R, SUN Q F. Human pulse recognition based on convolutional neural networks 2016[C]//Proceedings of 2016 International Symposium on Computer, Consumer and Control (IS3C).[S.l.]: IEEE, 2016.
- [6] LI Gaoyang, WATANABE K, ANZAI K, et al. Pulse-wave-pattern classification with a convolutional neural network[J]. Scientific Reports, 2019, 9(1): 14930.
- [7] OUYANG Chun, GAN Zhongxue, ZHEN Junjie, et al. Inter-patient classification with encoded peripheral pulse series and multi-task fusion CNN: Application in Type 2 diabetes[J]. Biomedical and Health Informatics, 2021, 25(8): 2168-2194.
- [8] 张选, 胡晓娟. 基于 GoogLeNet 和 ResNet 的深度融合神经网络在脉搏波识别中的应用[J]. 计算机系统应用, 2019, 28(10): 15-26.
ZHANG Xuan, HU Xiaojuan. Application of deep fusion neural network based on googlenet and ResNet in pulse wave recognition[J]. Computer Systems & Applications, 2019, 28(10): 15-26.
- [9] CHEN Jianhong, HUANG Huang, HAO Wenrui, et al. A machine learning method correlating pulse pressure wave data with pregnancy[J]. International Journal for Numerical Methods in Biomedical Engineering, 2020, 36(1): 3272.
- [10] 杨浩, 黄茂林, 蔡志鹏, 等. 融合 CNN 和 BiLSTM 的心律失常心拍分类模型[J]. 中国生物医学工程报, 2020(39): 719-726.
YANG Hao, HUANG Maolin, CAI Zhipeng, et al. Classification model of cardiac beat for arrhythmias by combining CNN and BiLSTM[J]. Chinese Journal of Biomedical Engineering, 2020(39): 719-726.
- [11] 马明艳, 陈伟, 吴礼发. 基于 CNN-BiLSTM 网络的入侵检测方法[J]. 计算机工程与应用, 2022, 58(10): 116-124.
MA Mingyan, CHEN Wei, WU Lifa. Intrusion detection method based on CNN_BiLSTM network[J]. Computer Engineering and Applications, 2021, 58(10): 116-124.
- [12] 颜建军, 刘章鹏, 刘国萍, 等. 基于深度森林算法的慢性胃炎中医证候分类[J]. 华东理工大学学报, 2019, 45(4): 593-599.
YAN Jianjun, LIU Zhangpeng, LIU Guoping, et al. Syndrome classification of chronic gastritis based on deep forest[J]. Journal of East China University of Science and Technology, 2019, 45(4): 593-599.
- [13] 高硕, 许少华. 一种集成 CNN 模型及其在 ECG 信号分类中的应用[J]. 软件导刊, 2019, 18(7): 24-31.
GAO Shuo, XU Shaohua. Application of an ensemble CNN model in ECG signal classification[J]. Software Guide, 2019, 18(7): 24-31.
- [14] 李洋, 董红斌. 基于卷积神经网络和 BiLSTM 网络特征融合的文本情感分析[J]. 计算机应用, 2018, 38(11): 3075-3080.
LI Yang, DONG Hongbin. Text sentiment analysis based on future fusion of convolution neural network and bidirectional long short-term memory network[J]. Journal of Computer Applications, 2018, 38(11): 3075-3080.
- [15] GRAVES A, LIWICKI M. A novel connectionist system for unconstrained handwriting recognition[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2009, 31(5): 855-868.
- [16] GREFF K, SRIVASTAVA R K, KOUTNIK J, et al. LSTM: A search space odyssey[J]. IEEE Transactions on Neural Network and Learning Systems, 2015, 28(10): 2222-2232.
- [17] GRAVES A, SCHMIDHUBER J. Frame wise phoneme classification with bidirectional LSTM and other neural network architectures[J]. Neural Networks, 2005, 18(56): 602-610.
- [18] 张冬雨. 面向脉诊的脉搏信号与血流信号分类研究[D]. 哈尔滨: 哈尔滨工业大学, 2010: 17-20.
ZHANG Dongyu. Research on classification of pulse signal and blood flow signal for pulse diagnosis[D]. Harbin: Harbin Institute of Technology, 2010: 17-20.
- [19] 黄玮, 余江维. 中医问诊内容及客观化研究探析[J]. 中华中医药杂志, 2019, 34(8): 3666-3668.

- HUANG Wei, YU Jiangwei. Exploration and analysis research of medical consultation content and objectification in traditional Chinese medicine[J]. China Journal of Traditional Chinese Medicine and Pharmacy, 2019, 34(8): 3666-3668.
- [20] 季忠, 刘旭. 基于波形特征和小波的脉搏波特征点识别研究[J]. 仪器仪表学报, 2016, 37(2): 379-386.
JI Zhong, LIU Xu. Study on feature points recognition of pulse wave based on waveform feature and wavelet[J]. Chinese Journal of Scientific Instrument, 2016, 37(2): 379-386.
- [21] MENG L, LIU L, PENG Y, et al. A data hiding scheme based on U-Net and wavelet transform[J]. Knowledge-Based Systems, 2021, 223(6): 107022.
- [22] NGUYEN H P, BARALDI P, ZIO E. Ensemble empirical mode decomposition and long short-term memory neural network for multi-step predictions of time series signals in nuclear power plants[J]. Applied Energy, 2020, 283(2): 116346.
- [23] 吴金玉, 张文强, 潘玲佼, 等. 一种结合自适应噪声完备经验模态分解和盲反卷积去除脑电中眼电伪迹的新方法[J]. 数据采集与处理, 2020, 35(4): 720-729.
WU Quanyu, ZHANG Wenqiang, PAN Lingjiao, et al. A new method for electrooculography artifact automatic removal based on CEEMDAN and BD in EEG signals[J]. Journal of Data Acquisition and Processing, 2020, 35(4): 720-729.
- [24] THOMAS T, ANTONY C S. Detection of transients in $1/f$ noise with the undecimated discrete wavelet transform[J]. IEEE Transactions on Signal Processing, 2000, 48(5): 1458-1462.
- [25] MIN L H, QIANG C, ZHENG M J, et al. Inhomogeneous image segmentation based on local constant and global smoothness priors[J]. Digital Signal Processing, 2021, 111: 102989.
- [26] 苏志刚, 吕江波, 郝敬堂. 基于平滑先验法去除脉搏波基线漂移[J]. 中国医学物理杂志, 2018, 35(10): 1197-1202.
SU Zhigang, LYU Jiangbo, HAO Jingtang. Removal of baseline drift of pulse wave based on smoothness prior[J]. Chinese Journal of Medical Physics, 2018, 35(10): 1197-1202.
- [27] 张伟. 基于卷积神经网络的轴承故障诊断算法研究[D]. 哈尔滨: 哈尔滨工业大学, 2017: 16-17.
ZHANG Wei. Study on bearing fault diagnosis algorithm based on convolutional neural network[D]. Harbin: Harbin Institute of Technology, 2017: 16-17.


作者简介:



杨晶东(1973-), 通信作者, 男, 博士, 副教授, 研究方向: 人工智能、机器学习与大数据分析、机器视觉等, E-mail: eerfriend@yeah.net。



陈磊(1996-), 男, 硕士研究生, 研究方向: 人工智能、机器学习在医学领域应用等, E-mail: 15528408115@163.com。



蔡书琛(1997-), 男, 硕士研究生, 研究方向: 人工智能、机器学习在医学领域应用等, E-mail: caisc1997@163.com。



解天晓(1996-), 男, 硕士研究生, 研究方向: 中医脉诊客观化研究, E-mail: 475296629@qq.com。



燕海霞(1979-), 女, 博士, 副教授, 研究方向: 中医脉诊客观化、标准化研究, E-mail: hjy2012ok@163.com。

(编辑: 陈璐)