

doi:10.3969/j.issn.1673-9833.2023.03.006

一种改进的 CNN-BiLSTM 心律失常分类方法

舒小华, 杨明俊, 焦龙飞

(湖南工业大学 轨道交通学院, 湖南 株洲 412007)

摘要: 基于一维心电信号, 提出了一种改进的卷积双向长短时记忆网络以实现心律失常的自动分类。基于卷积神经网络 (CNN) 及其注意力机制提取关键特征, 搭建双向长短时记忆网络 (BiLSTM) 挖掘心电信号的时间相关性, 最终实现心电信号的自动分类。在 MIT-BIH 心律失常数据集上进行的实验结果表明, 该方法在获得总体精度 99.32% 的基础上, 实现了稀有类别分类的提升, 其 S 与 F 类分类精确度分别提升了 1.02% 和 10.07%, 召回率分别提升了 12.52% 和 4.25%, 满足心律失常自动分类的检测要求。

关键词: 心电信号; 卷积神经网络; 注意力机制; 双向长短时记忆网络

中图分类号: TN911.7

文献标志码: A

文章编号: 1673-9833(2023)03-0034-08

引文格式: 舒小华, 杨明俊, 焦龙飞. 一种改进的 CNN-BiLSTM 心律失常分类方法 [J]. 湖南工业大学学报, 2023, 37(3): 34-41.

An Improved CNN-BiLSTM Arrhythmia Classification Method

SHU Xiaohua, YANG Mingjun, JIAO Longfei

(College of Railway Transportation, Hunan University of Technology, Zhuzhou Hunan 412007, China)

Abstract: Based on one-dimensional ECG signals, an improved convolution bidirectional long short-term memory network has been proposed for a realization of an automatic classification of arrhythmias. On the basis of the convolutional neural network (CNN) as well as its attention mechanism, with key features extracted, the bi-directional long short memory network (BiLSTM) is built to mine the temporal correlation of ECG signals, thus finally realizing the automatic classification of ECG signals. The experimental results on MIT-BIH arrhythmia data-set show that the proposed method achieves an improvement of rare category classification based on the overall accuracy of 99.32%, with the accuracy of S and F classification improved by 1.02% and 10.07% respectively; meanwhile, with the recall rate increased by 12.52% and 4.25% respectively as well, thus meeting the requirements of automatic classification of arrhythmia.

Keywords: ECG signal; CNN; attention mechanism; bi-directional long short memory network (BiLSTM)

1 研究背景

根据 2017 年世界卫生组织发布的报告, 在全球范围内, 心血管疾病已成为危害人类健康的头号疾

病, 每年因心血管疾病死亡人数均高于其他疾病导致的死亡人数。2016 年, 全球有超过 1 700 万人因心血管疾病死亡, 占该年总死亡人数的 31%, 其中因中风和心脏病导致的死亡人数高达 85%; 2019 年, 直

收稿日期: 2022-09-05

基金项目: 湖南省自然科学基金资助项目 (2020JJ5144)

作者简介: 舒小华 (1965-), 男, 湖南邵阳人, 湖南工业大学副教授, 硕士生导师, 主要研究方向为图像处理与智能交通, E-mail: sxhdata@163.com

接死于心脏病的人数达 900 万人, 占该年疾病致死人数总数的 16%^[1]。心律失常是心肌冲动形成的异常, 往往由各种器质性心血管疾病引发, 其发病可伴随着其他不同心血管疾病同时发作, 包括短时间内发作引发的猝死, 以及长时间损伤引发的器官衰竭。

随着心电分类技术的更新, 很多传统机器学习方法被应用于心电信号的自动分类中, 如 K -近邻算法、人工神经网络、使用多个决策树的随机森林, 以及对数据进行广义二元分类的支持向量机等多种分类算法。如 S. Sahoo 等^[2]提出了一种改进的 QRS 波(由 Q 波、R 波和 S 波组成)复度检测算法和基于多分辨率小波变换算法, 其将形态学特征和心律特征结合, 并利用支持向量机(support vector machine, SVM)进行分类, 实验结果表明, 其分类准确率和灵敏度分别为 98.39% 和 99.87%; Li T. Y. 等^[3]以心电信号小波分解后的信息计算熵系数作为代表特征, 使用随机森林(random forest, RF)算法, 对 MIT-BIH-AR 数据集进行 5 种心跳类型(N、L、R、V、P)的分类, 其准确率达到 94.61%; V. Gupta 等^[4]使用自回归(autoregressive model, AR)系数提取心电信号特征, 将 Biomedical Lab 数据库中的心电信号分为房性心动过速、房性早搏和窦性心律失常 3 类, 受试者精度达到了 95% 以上。尽管上述研究的心电分类方法取得了不错的效果, 但是依旧存在如下不足之处: 无论是基于传统机器学习还是基于形态学的方法, 都不能避免手动提取特征的繁琐性; 其次, 基于传统机器学习各类算法训练阶段效率不高, 准确率和识别速度都有待提升, 无法满足临床使用需求。

在传统机器学习的基础上, 科研工作者们进一步提出了基于深度学习的算法, 其通过参数训练获取心电信号的深层特征, 具有很强的学习逼近能力。其中, 近些年被广泛应用的卷积神经网络(convolutional neural networks, CNN)和循环神经网络(recurrent neural network, RNN), 已被应用于心律失常的识别分类中, 例如 Ö. Yildirim 等^[5]使用小尺寸多核心的卷积层构建 CNN 分类模型, 在心律失常数据集上的检测总体精度和灵敏度分别为 95.2% 和 93.52%; S. Chauhan 等^[6]使用 LSTM(long short-term memory)网络来实现 ECG(early gastric cancer)的正、异常二分类, 其分类准确率达 96.45%。Li Y. Z.^[7]等在 GCNN(generic convolutional neural network)的基础上, 应用微调技术, 将其修改为 TDCNN(tuned dedicated convolutional neural network), 取得在 5 min 内获得分类准确率达 96.89% 的效果。S. Saadatnejad 等^[8]采用由小波变换和多个 LSTM 递归神经网络

组成的新结构, 获得了 98.3% 的分类准确率。L. A. Abdullah 等^[9]将 CNN 和 LSTM 网络结合, 实现对心电的精确分类和检测, 对心肌梗死(MI)和心律失常分类的准确率分别为 98.10% 和 98.66%。叶兴扬等^[10]提出了一种融合深度残差网络(residual network, ResNet)和双向长短时记忆循环神经网络(bi-directional long short-term memory, BiLSTM)的心电信号分类算法, 其平均 $F_{1-score}$ 达 0.857 1。杨春德等^[11]将优化的一维 U-Net++ 用于心律不齐的片段信号识别, 在 4 类心律分类的准确率上达 98.10%。

从上述研究成果看, 基于深度学习技术的心律自动分类算法, 跳出了人为选择特征的弊端, 且具有较强的拟合性。但基于深度神经网络的心电分类算法仍有诸多不足, 深度神经网络训练所需的样本数据量巨大, 对硬件有一定要求, 且训练时间较长, 模型学习过程较为复杂, 计算量较大。

针对这些问题, 本文提出一种基于注意力机制的卷积神经网络和双向长短期记忆网络融合的心律失常自动分类模型。其通过卷积神经网络提取信号的深层次空间特征, 再利用双向长短期神经网络较强的序列学习能力和时间特征抽取能力进一步挖掘心电信号的时间特征, 在混合算法的基础上引入注意力机制, 考虑序列相关性的基础上在输入信号时合理分配注意力, 最后由全连接层和 Softmax 分类器将心电特征按照概率进行分类。在 MIT-BIH 心律失常数据集上进行训练测试, 总体准确率达 99.32%, 其中 $F_{1-score}$ 达 0.96, 取得了较好的实验效果。

2 基于注意力机制的卷积长短时记忆网络的心电信号自动分类

本研究在结合卷积神经网络和双向长短期记忆网络模型特点的基础上进行改进, 加入注意力机制, 提出 Attention-CNN-BiLSTM(ACNN-BiLSTM)模型结构, 通过数据集预处理、特征提取及降维、自动分类 3 个步骤, 实现对心律失常信号的自动分类。

2.1 心电信号预处理

心电信号的预处理主要包括心电信号去噪和心律分割两部分。采集到的原始心电信号包括工频噪声、肌电噪声、呼吸噪声 3 种主要噪声, 在利用深层卷积网络对其提取深层特征前, 需要进行滤波去噪, 以去除其中的低频噪声, 提升网络模型的鲁棒性和泛化能力。

心电信号去噪主要分为原始心电信号多尺度分解、各尺度小波系数的阈值处理, 以及处理之后的信

号重构 3 部分。本实验采用 db5 小波^[12]对原始信号进行 9 尺度小波分解：

$$X=D_1+D_2+D_3+\dots+D_9+A_9。 \quad (1)$$

式中： $D_1\sim D_9$ 为分解得到的心电信号中的高频信息； A_9 为第 9 层分解后得到的低频信息。

因为 MIT-BIH 数据集采样频率为 360 Hz，依据采样定理可知，原始信号最大频率低于 180 Hz，在对原始信号分解后，高频噪声主要集中于 D_1 、 D_2 部分，采用置 0 的方式将其除去， $D_3\sim D_9$ 层小波系数采用软阈值滤波法对其进行去噪处理，公式如下：

$$W = \begin{cases} |w| - \lambda, & |w| > \lambda; \\ 0, & |w| \leq \lambda. \end{cases} \quad (2)$$

$$\lambda = \frac{\text{median}|w| \times \sqrt{2 \times \ln P}}{0.6745}。 \quad (3)$$

式中： W 为过滤后的小波系数； λ 为阈值； P 为心电信号长度； w 为未处理小波系数； median 为中位数。

采用软阈值滤波法对其进行滤波后，去除其中幅值较小的小波系数即为噪声信号，对处理后的小波系数进行逆变换，获得去噪后的心电信号，信噪比(SNR)为 19.6，图 1 分别展示了预处理前后的心电信号波形，由图可知其符合实验要求。

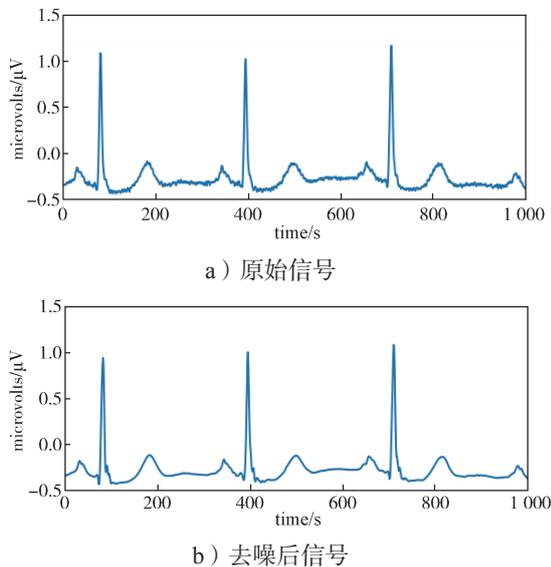


图 1 信号去噪前后对比图

Fig. 1 Signal denoising contrast diagrams

心律分割是在完成心电信号去噪后，将连续的心电信号切分成相同长度的心律片段。在心律分割长度的选择上，无论心律过长还是过短，都不利于后续的特征提取。心律信号过长，会导致信息冗余甚至造成前后心律的信息丢失，心律信号过短，则可能无法提取到有效特征。本文选用 R 波定位分割算法，以 MIT-BIH 数据集标注的 R 波位点为准，在 R 波位

点前截取 100 个采样点，R 波位点后截取 199 个采样点，将长度为 30 min 的心电数据样本划分成单个片段长度为 300 个采样点的心电信号片段。

2.2 基于注意力机制的卷积 BiLSTM 模型

本研究中将注意力机制、卷积神经网络、长短期记忆神经网络结合，提出 Attention-CNN-BiLSTM (ACNN-BiLSTM) 模型，自动学习心电信号特征，对心电信号进行分类。通过注意力机制让模型拥有分辨能力，使其对原始信号赋予不同的权重，将得到的权重与输入信号合入卷积神经网络部分，经过卷积池化操作缩减为较小尺寸且固定长度的 1 维特征向量，再将特征向量送入 BiLSTM 网络中进行训练和分类，最后通过 Softmax 分类函数，完成最后的心律失常信号自动分类。

卷积神经网络通过卷积层和激活函数，能够有效地提取心电特征，输入信号通过卷积核作用于输入信号的感受野，获取初步特征，紧接着池化层对初步特征进行挑选和过滤，以减少网络的计算量。依据心电信号的特点，本研究采用 CNN 分类模型^[13]，并且采用卷积核大小递增的连续卷积池化组合。通过连续的卷积池化等操作遍历整个序列，提取心电信号的局部信息，挖掘其深层特征，以实现心电特征的初步提取。

BiLSTM 是由向前推算与向后推算两个长短期记忆神经网络组合而成的。LSTM 网络通过对输入门、输出门和遗忘门的控制，不仅能够获取当前输入信息和当前点之前的输出信息^[14]，而且保留了时间步与各层级之间反向传播的误差，使得网络拥有获取长距离信息之间因果联系的能力。双向长短期记忆网络，相比长短期记忆网络，能够捕捉前一时间段和后一时间段的因果关系，使得该网络既可以获取当前信号之前时段的重要特征，又可以获取当前时刻之后的特征^[15]，因此运用在心电分类上能够突出心电信号的时序性，获取当前信号的上下文信息，深度挖掘心电信号的时间相关性。

ACNN-BiLSTM 网络模型结构如图 2 所示。

在注意力机制中，将切割后长度为 300 的心律信号经 Softmax 函数归一化形成权值，通过 Permute 函数转置以及 Multiply 函数将权值与原始心律信号合成，突出心律原有特征。

在 CNN 特征提取部分，首先将心电信号输入注意力模块中，然后通过注意力机制对 ECG 心电信号序列进行编解码分析，对信号各个位点赋予不同程度的权值，使用 4 个卷积层，4 层卷积核依次为 4 个 21×1 、16 个 23×1 、32 个 25×1 、64 个 27×1 ，卷积核步长均为 1。每次卷积后选择线性修正单元

(rectified linear unit, ReLU) 作为激活函数。池化层均选择大小为 3, 滑动步长为 2 的最大池化层, 对特征向量进行压缩处理, 并使用 Dropout 防止其过拟合。卷积部分结束后, 将长度为 300 的心电信号片段压缩至长度为 38 的特征向量。

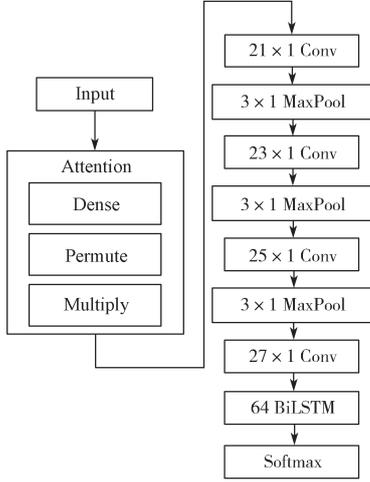


图2 ACNN-BiLSTM 网络模型结构

Fig. 2 ACNN-BiLSTM network model structure

在 BiLSTM 部分, 卷积结构中提取的空间信号特征被送入 64 个单元的双向 LSTM 网络进行时间分析, 挖掘心电信号之间存在的时间动态并进行学习和映射; 最后使用全连接层和 Softmax 函数, 得到 5 种不同类别的概率值, 依据输出的概率进行预测, 完成最后的心电分类。

2.3 数据不平衡优化

由于 MIT-BIH 心律失常数据库是一个极不平衡的数据库, S、V、F、Q 4 种心律个数相对于 N 类心律严重不足, 这使得在训练时其余 4 种心律相对于 N 类心律训练不足, 导致模型对少数类心律的特征学习不足, 往往使得 S 或 F 类识别准确率较低, 最终导致模型实际应用效果不佳。为平衡 S、V、F、Q 4 种类别心律的样本训练集数据量, 本文采用自适应综合算法 (adaptive synthesis algorithm, ADASYN) 对训练集 S、V、F、Q 4 类心律样本进行过采样。ADASYN 算法是由 He H. B. 等^[16]在 2008 年提出的一种过采样算法, 该算法根据不同少数群体的学习难度, 对不同的少数群体样本使用加权分布, 其中, 与更容易学习的少数群体样本相比, 该算法将为更难学习的少数群体示例生成更多的合成数据。相比于早前提出的 SMOTE (synthetic minority oversampling technique) 合成少数类过采样技术^[17], 解决了对于所有少数样本一视同仁, 不考虑近邻样本信息而导致的样本混叠、分类不佳等现象。

ADASYN 算法的具体流程如下。

1) 计算待合成的样本数量,

$$G = (m_i - m_s) \times \beta. \quad (4)$$

式中: m_i 与 m_s 分别为多数类与少数类样本数量; β 为数据平衡参数, $\beta \in [0, 1]$, 若 β 取值为 1, 则表示经上采样后多数类与少数类二者数量完全平衡。

2) 计算 K 近邻中多数类所占比例 r_i , $r_i \in [0, 1]$, 其计算式为

$$r_i = \Delta_i / K. \quad (5)$$

式中: Δ_i 为 K 近邻中多数类样本数, $i = 1, 2, \dots, m_s$ 。

3) 根据 n 维空间中的欧几里德距离查找 K 个最近邻, 并计算比率 \hat{r}_i :

$$\hat{r}_i = r_i / \sum_{i=1}^{m_s} r_i; \quad (6)$$

依据相关权重, 计算少数类样本还需要合成的样本数目 g ,

$$g = \hat{r}_i \times G. \quad (7)$$

4) 根据 g 计算每个少数类样本需要生成的数目, 使用 SMOTE 算法生成样本,

$$s_i = x_i + (x_{zi} - x_i) \times \lambda, \quad (8)$$

式中: s_i 为合成样本; $\lambda \in [0, 1]$ 。

从 K 个最近邻样本中随机选择一个少数类样本 x_{zi} 作为 x_i , x_i 为少数类样本中的第 i 个样本。

5) 调用 imblearn 函数, 设置数据上采样个数为 60 000, 对训练集 S、V、F、Q 类进行上采样, 使得上述 4 类训练集数量级提升至与 N 类相同, 样本结果如表 1 所示。

表 1 各类实验心率数量详情

Table 1 List of experimental heart beat data

数据类别	心 律 类 别				
	N	S	V	F	Q
训练集	66 790	1 768	5 562	643	3 109
训练集上采样	66 790	60 095	60 012	60 099	59 998
测试集	16 720	441	1 373	155	779

表 2 为未对训练集进行处理和经过 ADASYN 算法扩充训练集的精确度对比, 可以得知各种类精确度都有不同程度的提升, 其中 S、V 均有小幅度提升, F 类提升最为显著。

表 2 ACNN-BiLSTM 网络数据集扩充前后精确度对比

Table 2 ACNN-BiLSTM network dataset

训练集处理	心 律 类 别					%
	N	S	V	F	Q	
不处理	99.62	89.18	97.03	79.12	99.56	
ADASYN 算法扩充	99.67	90.70	98.76	89.03	99.74	

2.4 模型训练与分类

设置训练迭代次数为 120 次, 每批处理的样本数 (batch_size) 为 128。在全连接层中, dropout 的值为 0.2。dropout 是指在训练过程中, 每训练一次更新参数会随机断开一定比例的神经元, 使用 dropout 随机断开部分神经元相当于减少整个模型参数数量, 可缓解网络在训练时遇到的过拟合作用。使用自适应矩估计 (adaptive moment estimation, Adam) 算法作为模型优化器, 采用交叉熵损失函数 (cross entropy loss, CEL) 计算损失率。学习率的初始值设置为 0.01, 每 20 轮衰减 20%, 即采用离散下降模式。

$$L(\theta) = -\frac{1}{N} \sum_{n=1}^N \sum_{j=1}^C Y_{n,j} (\log_2(p_{n,j}))。 \quad (9)$$

式中: $Y_{n,j}$ 为第 n 个心律数据的心律失常类别; C 为心律分类的类别数; N 为训练集样本个数。

ACNN-BiLSTM 网络末端的全连接层使用 Softmax 激活函数将输出结果分为 5 类, 该层的 5 个节点分别代表 AAMI 标准下的 5 种类别, 即 N、S、V、F、Q, 5 种类别的概率计算公式如下:

$$p = e^{v_i} / \sum_{j=1}^k e^{v_j}。 \quad (10)$$

式中: k 为神经网络输出的类别数; v_j 为输出向量 v 中第 j 个输出或类别的值; i 为当前计算的类别, 其结果在 0 到 1 之间, 且所有类别的概率值之和为 1。

3 实验与结果分析

3.1 实验数据

实验所用数据来源于 MIT-BIH 心律失常数据库, 该数据库由麻省理工学院开发, 包括来自 47 位受试者 (编号 201 与编号 202 为同一受试者个体) 的 48 条长度为 30 min 的心律信号, 并带有专业医生标注的 18 种心律类型的标签注释, 每条信号的采样频率为 360 Hz。使用美国医疗仪器促进协会 (Association for the Advancement of Medical Instrumentation, AAMI) 制定的标准作为本文的分类参考, 共获得了 5 大类不对称心律 97 340 个, 为保持导联一致性, 去除 102 与 104 两个 V5 导联, 心律类别的划分情况如表 3 所示。对下列数据进行预处理, 在经过去噪过程后, 选择采样点数为 300 得到数据集样本。其中 80% 的数据样本用于网络模型训练, 但是考虑到该数据集高度不平衡, 故使用 ADASYN 算法, 将小类别训练集扩充到相同数量级; 剩余 20% 的数据集用于验证, 二者相互独立, 没有重复。

表 3 AAMI 标准在心电信号分类中的描述

Table 3 Description of AAMI standard in ECG classification

心律类别	AAMI 标准类别	类别数量
正常 (NOR)		
左束支传导阻滞 (LBBB)		
右束支传导阻滞 (RBBB)	Normal (N)	83 513
房性逸搏 (AE)		
结性逸搏 (NE)		
房性早搏 (AP)		
异常房性早搏 (aAP)	Supraventricular (S)	2 184
交界性早搏 (NP)		
室上性早搏 (SP)		
室性早搏 (PVC)	Ventricular (V)	6 975
室性逸搏 (VE)		
心室融合心跳 (fVN)	Fusion (F)	801
起搏心跳 (P)		
起搏融合心跳 (fPN)	Unknown (Q)	3 867
未分类心跳 (U)		

3.2 评价方法

本次实验使用如下 4 个评价指标来综合评估模型的性能, 分别是总体精度 OA 、精确率 (precision) η_p 、召回率 (recall) η_r 、 $F_{1-score}$, 公式定义如式 (11)~(15) 所示, 并使用混淆矩阵进行计算。准确率 (总体精度) 是所有分类正确的真阴性 T_N 与真阳性 T_p 占全部样本数的比率, 是衡量分类问题中最简单且直观的评价指标。精确率 (真阳性率) 指模型预测为正的样本中实际也为正的样本占被预测为正的样本的比例, 精确率越高表示该类别的预测结果越准确, 被误诊为其他类别的概率越低。灵敏度也称召回率, 指该类被预测正确的样本占该类别的比例, 召回率越高说明该类别被漏诊的概率越低。 $F_{1-score}$ 是精确率和召回率的调和平均值, 该值越高, 模型越稳健。

$$OA = \frac{T_p + T_N}{T_p + T_N + F_p + F_N}, \quad (11)$$

$$\eta_p = \frac{T_p}{T_p + F_p}, \quad (12)$$

$$\eta_r = \frac{T_p}{T_p + F_N}, \quad (13)$$

$$F_{1-score} = \frac{(1+\beta^2) \cdot \eta_p \cdot \eta_r}{\beta^2 \cdot \eta_p + \eta_r}。 \quad (14)$$

式中: T_p 为真阳性, 表示真实类别为阳性的心律样本被分类为阳性的个数; F_N 为假阴性, 表示真实类别为阳性的心律样本被分类为阴性的个数; T_N 为真阴性, 表示真实类别为阴性的心律样本被分类为阴性的个数; F_p 为假阳性, 表示真实类别为阴性的心律

样本被分类为阳性的个数; β 是一个系数, 用于调整精确度与召回率的相对重要性, 通常取 $\beta=1$, 此时式 (14) 为

$$F_{1-score} = \frac{2 \cdot \eta_p \cdot \eta_r}{\eta_p + \eta_r} \quad (15)$$

3.3 实验结果

实验使用 TensorFlow 深度学习框架, 基于 Python 语言, 调用 Keras 库。所有实验研究均在 CPU: Intel(R) Core(TM) i5-7300HQ CPU @ 2.50 GHz, GPU: NVIDIA GeForce GTX 1050, Windows11 操作系统的计算机完成。卷积神经网络方面根据现有大卷积核进行改进, 全部使用最大池化, 保证特征不被模糊, 提高特征辨识度。将卷积神经网络压缩后的特征信号送入双向长短时记忆网络中, 提取特征信号中的时间特性, 并通过 dropout 层随机断开 20% 的神经元, 防止过拟合。通过 flatten 层将双向长短时记忆网络的多维输入一维化, 最后通过全连接层将一维化的输出片段计算预测概率, 完成最后的心律失常分类。

图 3 分别给出了使用传统 CNN 网络以及 ACNN-BiLSTM 网络完成 120 次迭代的训练与测试性能。

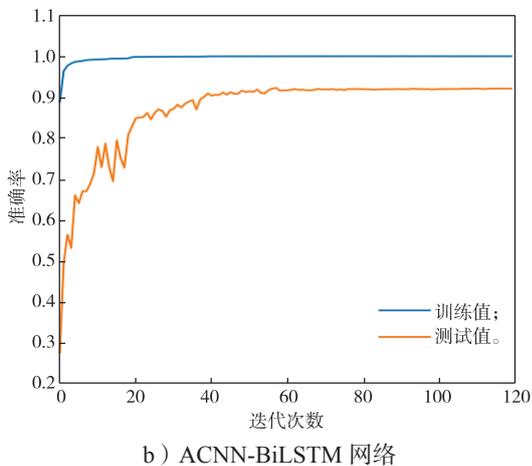
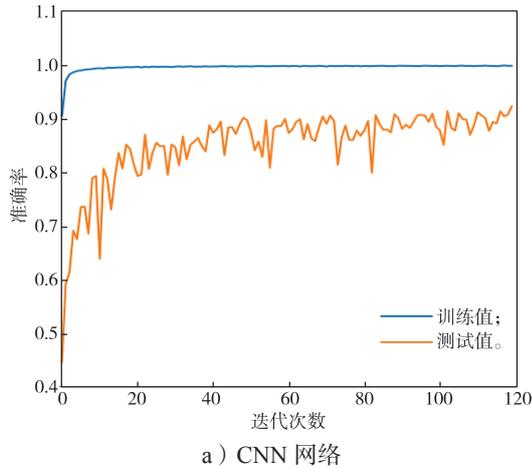


图 3 网络训练和测试性能图

Fig. 3 Network training and test performance charts

由图 3 可以得出, 两者都具有较好的性能。仅使用传统 CNN 做特征提取的模型测试集获得了 98.82% 的准确率, 而使用 ACNN-BiLSTM 网络的模型在同一时期内实现了 99.32% 的测试集准确率。

将传统的 CNN 网络与经过改进的 ACNN-BiLSTM 网络在上述相同的试验条件下进行对比试验, 得出的两种不同网络模型各类别评价指标数值如表 4 所示。

表 4 CNN 网络和 ACNN-BiLSTM 网络相关评价指标数据
Table 4 CNN network and ACNN-BiLSTM network relevant evaluation indicators %

网络模型	评价指标	心律类别				
		N	S	V	F	Q
CNN	η_p	99.41	89.68	96.73	76.51	99.48
	η_r	99.41	81.46	98.12	88.37	99.84
	$F_{1-score}$	99.41	85.37	97.42	82.01	99.67
ACNN-BiLSTM	η_p	99.67	90.70	98.76	89.03	99.74
	η_r	99.65	91.53	98.26	92.62	99.74
	$F_{1-score}$	99.66	91.12	98.51	90.79	99.74

分析表 4 中的数据, 可知两模型在 S 类与 F 类上的评价指标值相对较低。这可能是因为 S 类与 F 类的样本数量相对较少, 在训练过程中网络关注度不如其他大类, 虽然使用 ADASYN 算法将训练集扩充至同一数量级进行数据增强, 但只能缓解而无法彻底解决此问题。同时也注意到, ACNN-BiLSTM 网络在各类型评价指标上均有不同程度的提升, 特别是在 S 类与 F 类上, 提升幅度较大。其中, S 类的精确率与召回率分别提升了 1.02% 和 10.07%, F 类的精确率与召回率分别提升了 12.52% 和 4.25%, 这说明了该模型基于 CNN 模型改进后的有效性。在测试时间上, CNN 网络参数结构更加简单, 因此在训练阶段用时为 2 811.01 s, 约 0.78 h, 平均测试持续时间仅为 4.92 s。本文所给模型是在 CNN 模型基础上添加了注意力机制以及 BiLSTM 模块, 因而更注重分类结果的精确性, 但是在一定程度上增加了分类所需时间, 训练阶段用时为 5 546.37 s, 约 1.54 h, 在准确率提升的同时测试时间仅为 9.24 s, 符合预期要求。

图 4 为测试集混淆矩阵, 表 5 为两者评价指标结果对比。由表中结果可知, CNN 网络在 19 468 个心律数据上的总体精度为 98.82%, 精确度以及召回率分别为 93.45% 和 92.36%; 而 ACNN-BiLSTM 网络在测试集数据上的总体精度达 99.32%, 精确度及召回率也均高于前者, 分别达 96.36% 和 95.58%, 综合指标 $F_{1-score}$ 也优于 CNN 网络模型, 说明模型的稳健程度更高。此外, 实验的训练集与测试集无重复数据, 证明该模型对心律失常分类有较强的适应性。

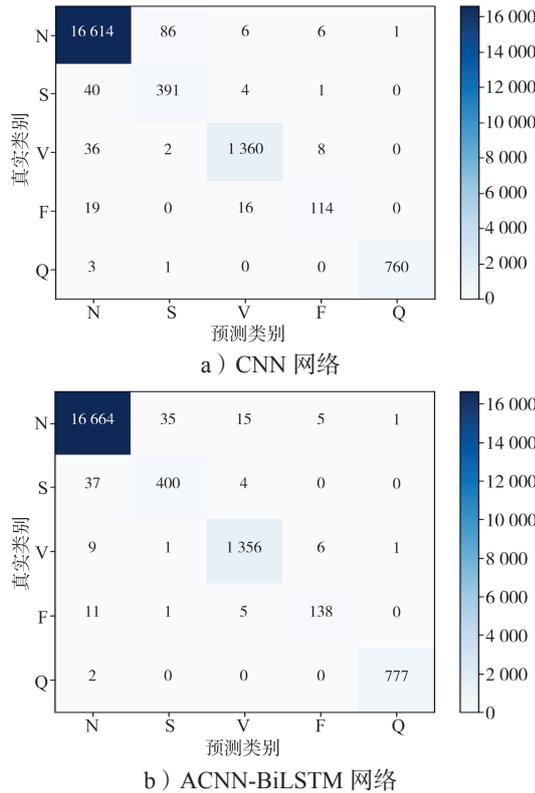


图4 网络模型测试集混淆矩阵

Fig. 4 Network model test set confusion matrix

表5 CNN网络和ACNN-BiLSTM网络评价指标结果对比

Table 5 CNN network and ACNN-BiLSTM network evaluation indicators

网络模型	OA	η_p	η_r	$F_{1-score}$
CNN	98.82	93.45	92.36	92.78
ACNN-BiLSTM	99.32	96.36	95.58	95.96

将 ACNN-BiLSTM 模型与其他基于 MIT-BIH 数据集的心律失常分类模型的性能进行对比, 分类结果各指标数据具体如表 6 所示。分析表 6 中的数据, 可以得知提出的 ACNN-BiLSTM 模型相较于其他文献模型在心电信号实现自动分类方面具有一定的优势。在整体准确度上达到了 99.32%, 高于其他方法的相应值; 在精确度上达到了 96.36%, 略高于文献 [19] 的 96.05%; 在召回率上略低于文献 [18], $F_{1-score}$ 指标为精确度与召回率的调和平均, 达到了 95.96%, 同样仅次于文献 [18] 的对应值, 优于文献 [19] 和 [20] 的对应值, 处于较好水平。综合考虑, 实验模型基于注意力机制的卷积神经网络与双向长短时记忆神经网络模型, 能够有效地对心律信号进行压缩和特征提取, 从而获得较高的分类准确率。

表6 心律失常分类结果性能指标对比

Table 6 Comparison of performance indexes of classification results of arrhythmia

文献	数据处理	信号长度	模型	性能 / %			
				OA	η_p	η_r	$F_{1-score}$
[18]	-	260 samples	CNN	94.03	97.85	96.71	97.27
[19]	-	73 × 73	CNN	96.05	96.05	72.06	82.35
[20]	SMOTE	280 samples	CNN-BiLSTM	98.71	92.60	94.44	93.53
本文	ADASYN	300 samples	CNN	98.82	93.45	92.36	92.78
			ACNN-BiLSTM	99.32	96.36	95.58	95.96

4 结语

ACNN-BiLSTM 网络模型在卷积神经网络的基础上, 结合注意力机制与双向长短时记忆网络的优势, 实现心电信号的自动分类。本文模型相较于传统 CNN 模型, 在卷积运算前加入注意力机制和双向长短时记忆网络, 注意力机制在卷积操作前给心电片段赋予注意力权重, 让模型专注于特定片段; 双向长短期记忆网络获取时间维度上特征, 挖掘心电信号的时间相关性。在 MIT-BIH 数据集进行仿真实验中, 该网络的分类准确率达 99.32%, 精确率和召回率也高达 96.36% 和 95.58%, 对于数量较少的 S 类与 F 类, 其精确度和召回率分别提升了 1.02%, 10.07% 和 12.52%, 4.25%, 这说明本文模型在准确率等方面较原有模型有较大提升, 符合实验预期。由于本研究

使用了 ADASYN 算法, 导致数据集扩充, 延长了整体的训练时间, 本模型较原有 CNN 增加了 BiLSTM 网络, 在一定程度上增加了网络的复杂性, 对移动健康设备有一定的运算压力, 还需要进一步研究改进后的检测效率。

参考文献:

[1] World Health Organization. Cardiovascular diseases[EB/OL]. (2017-05-17)[2022-08-12]. [https://www.who.int/zh/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/zh/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)).

[2] SAHOO S, KANUNGO B, BEHERA S, et al. Multiresolution Wavelet Transform Based Feature Extraction and ECG Classification to Detect Cardiac Abnormalities[J]. Measurement, 2017, 108: 55-66.

- [3] LI T Y, ZHOU M. ECG Classification Using Wavelet Packet Entropy and Random Forests[J]. *Entropy*, 2016, 18(8): 285.
- [4] GUPTA V, MITTAL M. KNN and PCA Classifier with Autoregressive Modelling During Different ECG Signal Interpretation[J]. *Procedia Computer Science*, 2018, 125: 18–24.
- [5] YILDIRIM Ö, PŁAWIAK P, TAN R S, et al. Arrhythmia Detection Using Deep Convolutional Neural Network with Long Duration ECG Signals[J]. *Computers in Biology and Medicine*, 2018, 102: 411–420.
- [6] CHAUHAN S, VIG L. Anomaly Detection in ECG Time Signals Via Deep Long Short-Term Memory Networks[C]//2015 IEEE International Conference on Data Science and Advanced Analytics. Paris: IEEE, 2015: 1–7.
- [7] LI Y Z, PANG Y W, WANG J, et al. Patient-Specific ECG Classification by Deeper CNN from Generic to Dedicated[J]. *Neurocomputing*, 2018, 314: 336–346.
- [8] SAADATNEJAD S, OVEISI M, HASHEMI M. LSTM-Based ECG Classification for Continuous Monitoring on Personal Wearable Devices[J]. *IEEE Journal of Biomedical and Health Informatics*, 2020, 24(2): 515–523.
- [9] ABDULLAH L A, AL-ANI M S. CNN-LSTM Based Model for ECG Arrhythmias and Myocardial Infarction Classification[J]. *Advances in Science, Technology and Engineering Systems*, 2020, 5(5): 601–606.
- [10] 叶兴扬, 韦张跃昊, 严 卉, 等. 基于 ResNet 和 Bi-LSTM 模型融合的心电信号分类 [J]. *航天医学与医学工程*, 2021, 34(3): 244–251.
YE Xingyang, WEI-ZHANG Yuehao, YAN Hui, et al. ECG Signal Classification Based on Fusion Model of ResNet and Bi-LSTM Network[J]. *Space Medicine & Medical Engineering*, 2021, 34(3): 244–251.
- [11] 杨春德, 贾 竹, 李欣蔚. 基于 U-Net++ 的心电信号识别分类研究 [J]. *计算机科学*, 2021, 48(10): 121–126.
YANG Chunde, JIA Zhu, LI Xinwei. Study on ECG Signal Recognition and Classification Based on U-Net++[J]. *Computer Science*, 2021, 48(10): 121–126.
- [12] DONOHO D L. De-Noising by Soft-Thresholding[J]. *IEEE Transactions on Information Theory*, 1995, 41(3): 613–627.
- [13] 张宇微. 面向心血管疾病识别的心电信号分类研究 [D]. 济南: 济南大学, 2019.
ZHANG Yuwei. Multi-Classification of ECG Signals for Cardiovascular Disease Identification[D]. Jinan: University of Jinan, 2019.
- [14] WILLIAMS R J, ZIPSER D. A Learning Algorithm for Continually Running Fully Recurrent Neural Networks[J]. *Neural Computation*, 1989, 1(2): 270–280.
- [15] LIU H, LEE I. End-to-End Trajectory Transportation Mode Classification Using Bi-LSTM Recurrent Neural Network[C] //2017 12th International Conference on Intelligent Systems and Knowledge Engineering (ISKE). Nanjing: IEEE, 2017: 1–5.
- [16] HE H B, BAI Y, GARCIA E A, et al. ADASYN: Adaptive Synthetic Sampling Approach for Imbalanced Learning[C]//2008 IEEE International Joint Conference on Neural Networks. Hong Kong: IEEE, 2008: 1322–1328.
- [17] CHAWLA N V, BOWYER K W, HALL L O, et al. SMOTE: Synthetic Minority Over-Sampling Technique[J]. *Journal of Artificial Intelligence Research*, 2002, 16: 321–357.
- [18] ACHARYA U R, OH S L, HAGIWARA Y, et al. A Deep Convolutional Neural Network Model to Classify Heartbeats[J]. *Computers in Biology and Medicine*, 2017, 89: 389–396.
- [19] ZHAI X L, TIN C. Automated ECG Classification Using Dual Heartbeat Coupling Based on Convolutional Neural Network[J]. *IEEE Access*, 2018, 6: 27465–27472.
- [20] SHOUGHI A, DOWLATSHAHI M B. A Practical System Based on CNN-BLSTM Network for Accurate Classification of ECG Heartbeats of MIT-BIH Imbalanced Dataset[C]//2021 26th International Computer Conference, Computer Society of Iran (CSICC). Tehran: IEEE, 2021: 1–6.

(责任编辑: 廖友媛)