

基于卷积长短时记忆网络的心律失常分类方法

柯丽* 王丹妮 杜强 姜楚迪

(沈阳工业大学电气工程学院 沈阳 110870)

摘要: 心律失常等慢性心血管疾病严重影响人类健康, 采用心电信号(ECG)实现心律失常自动分类可有效提高该类疾病的诊断效率, 降低人工成本。为此, 该文基于1维心电信号, 提出一种改进的长短时记忆网络(LSTM)方法实现心律失常自动分类。该方法首先设计深层卷积神经网络(CNN)对心电信号进行深度编码, 提取心电信号形态特征。其次, 搭建长短时记忆分类网络实现基于心电信号特征的心律失常自动分类。基于MIT-BIH心律失常数据库进行的实验结果表明, 该方法显著缩短分类时间, 并获得超过99.2%的分类准确率, 灵敏度等评价参数均得到不同程度的提高, 满足心电信号自动分类实时高效的要求。

关键词: 心电信号; 心律失常; 深度学习; 卷积神经网络; 长短时记忆网络

中图分类号: TP391; R540.41

文献标识码: A

文章编号: 1009-5896(2020)08-1990-09

DOI: 10.11999/JEIT190712

Arrhythmia Classification Based on Convolutional Long Short Term Memory Network

KE Li WANG Danni DU Qiang JIANG Chudi

(School of Electrical Engineering, Shenyang University of Technology, Shenyang 110870, China)

Abstract: Chronic cardiovascular diseases such as arrhythmia seriously affect human health. The automatic classification of ElectroCardioGram(ECG) signals can effectively improve the diagnostic efficiency of such diseases and reduce labor costs. To tackle this problem, an improved Long-Short Term Memory (LSTM) method is proposed to achieve automatic classification of one dimensional ECG signals. Firstly, deep Convolutional Neural Network (CNN) is designed to deeply encode the ECG signal, and ECG signal morphological features are extracted. Secondly, the LSTM classification network is used to realize automatic classification of arrhythmia of ECG signal features. Experimental studies based on the MIT-BIH arrhythmia database show that the training duration is significantly shortened and more than 99.2% classification accuracy is obtained. Sensitivity and other evaluation parameters are improved to meet the real-time and efficient requirements for automatic classification of ECG signals.

Key words: ElectroCardioGram (ECG) signal; Arrhythmia; Deep learning; Convolutional Neural Network (CNN); Long Short-Term Memory (LSTM)

1 引言

世界卫生组织统计发现, 2016年约有1790万人死于心血管疾病, 占全球死亡人数的31%^[1]。心律失常是心血管疾病中重要的一组疾病, 可单独发作亦可与其他心血管疾病伴发, 可持续累及心脏而致

其衰竭亦可突然发作致人猝死, 临床上通常使用心电图诊断心律失常。针对心律失常的突发性以及难以预测性, 前期诊断和实时监控是关键。因此, 建立实时有效的心律失常自动分类系统不仅能够及时发现患者心脏异常情况提高治疗效率还能大大降低医生工作量, 具有十分重要的现实意义。

心律失常自动分类技术主要包括信号预处理、特征提取和降维以及自动分类3个阶段。信号预处理包括去除心电信号在测量过程中出现的工频噪声以及肌电噪声等干扰, 同时对心电信号进行分段, 便于后续特征提取和自动分类的精细识别。心电信号特征提取主要使用形态特征、时频特征等^[2,3],

收稿日期: 2019-09-16; 改回日期: 2020-02-20; 网络出版: 2020-03-23

*通信作者: 柯丽 keli@sut.edu.cn

基金项目: 国家自然科学基金(51377109), 辽宁省自然科学基金(2019-ZD-0204)

Foundation Items: The National Natural Science Foundation of China (51377109), The Natural Science Foundation of Liaoning Province (2019-ZD-0204)

再使用诸如主成分分析等特征降维方法得到心电信号的关键特征。例如, Ye等人^[2]利用小波变换和独立分量分析与心电信号形态特征相结合, 突出显示信号形态上的细微尺度变化, 得到有效心电信号特征集合。高兴蛟等人^[4]利用近邻保持嵌入(Neighborhood Preserving Embedding, NPE)的流形学习算法获取心拍空间中的局部流行结构特征。在心电信号自动分类方面, 主要有统计模式识别法^[5]和结构模式识别法^[6]等。随着技术的不断创新, 多种模式识别方法被用于心律失常的自动分类, 比如基于浅层机器学习的随机森林、支持向量机(Support Vector Machines, SVM)、多层感知机(MultiLayer Perceptron network, MLP)等方法以及基于深度学习的多种智能分类算法。如Li等人^[7]使用基于遗传算法的最小二乘双支持向量机结合起来, 实现5种心律失常的分类并得到99.14%的分类准确率。由于心电信号的独特性质, 尽管上述心电信号分类系统取得较好效果, 但还存在以下限制: (1) 不同患者甚至同一患者不同时刻的心电信号波形和模式不同, 很难将统一的特征作为评估手段; (2) 人工选择心电信号特征的有效性受到诸多因素影响, 且时间和费用成本较大; (3) 浅层神经网络算法及部分机器学习方法的训练效率有限, 难以用于临床。

深度学习方法能够通过层次化概念自动学习特征, 避免了人工特征选择过程。其中, 卷积神经网络(Convolution Neural Network, CNN)和循环神经网络(Recurrent Neural Network, RNN)近年来在众多领域取得优秀成果^[8,9], 并且已有一些学者将深度学习应用到心律失常的自动分类研究中。例如, Meng等人^[10]将原始ECG信号与RR间期作为输入, 通过4层深度置信网络(Deep Belief Networks, DBNs)实现6类心律失常分类, 总体精度98.49%。Acharya等人^[11]使用9层CNN模型实现5种心律失常的识别与分类, 获得了94.03%的分类准确率。Zhai等人^[12]利用8层CNN完成室上异位搏动和心室异位搏动两种心律失常的检测。为了挖掘心电信号内部连续性特征, Cheng等人^[13]利用RNN的变体, 长短时记忆(Long Short Term Memory, LSTM)网络实现基于心电信号的阻塞睡眠呼吸暂停检测, 取得了97.8%的准确率。Tan等人^[14]将CNN和LSTM网络模型串联在一起, 实现冠状动脉疾病的自动诊断。吴志勇等人^[15]提出了基于模糊C均值的深度信念网络FCMDBN模型结构实现5种心律失常的分类, 总体准确率达到96.54%。Hannun等人^[16]使用34层的深度卷积神经网络对来自大约50000名患者的91232条ECG记录的数据集进行训练, 实现了

12种心律类型的分类。从上述文献来看, 基于深度学习的心电自动分类技术相对传统方法优势突出, 摆脱了人工选择特征的局限且具有更强的拟合能力。然而神经网络的学习过程比较复杂, 模型计算量较大, 并且需要巨大带标签的数据样本对网络进行训练, 时间和硬件成本都比较高。

为解决上述问题, 综合卷积神经网络与循环神经网络的优势, 本文提出一种结合深度卷积神经网络和长短时记忆网络多层概率融合的卷积长短时记忆网络(Convolutional Long Short Term Memory Network, C-LSTM)心电信号心律失常自动分类模型。参考医生诊断方法, 首先提出深度卷积神经网络自动提取信号深层次形态特征, 降低信号维度, 压缩信号大小; 然后设计长短时记忆网络学习卷积运算提取到的信号特征之间深层联系, 以更低的计算成本, 加快模型收敛, 解决梯度消失问题; 最后通过全连接层和Softmax函数完成心律失常的自动分类。在MIT-BIH心律失常数据库进行的仿真实验结果表明, 本文方法分类准确率高达99.23%且有效缩短模型训练时间, 以较高的数据传输率实现基于心电信号的心律失常高效分类。

2 基于卷积长短时记忆网络的心电信号自动分类

本文在综合深度CNN和LSTM网络模型特点的基础上, 结合心电信号自身性质, 提出C-LSTM网络模型结构。通过心电信号预处理、特征提取和降维以及自动分类3个步骤实现基于心电信号的心律失常自动分类。

2.1 心电信号预处理

心电信号在采集过程中受到工频干扰、肌电噪声等因素的影响, 但由于本文后续用到的深度学习方法能够自动挖掘心电信号的深层次特征, 因此在信号预处理阶段仅进行简单的滤波, 加强网络模型的泛化能力及鲁棒性。考虑心电信号噪声类型和频率不同, 为提高对不同类型噪声的适应性, 本文首先使用35 Hz的低通滤波器去除信号中部分噪声和干扰。然后, 使用db6小波对心电信号进行6层分解, 自适应选择阈值对信号去噪, 之后通过小波逆变换进行信号重构, 波形平均信噪比为42.93。如图1(a)和图1(b)分别展示了预处理前后的心电信号波形。

滤波之后提取心电信号中每个完整的心跳周期波形, 如图1(c)所示, 采用QRS波的斜率突变性结合小波变换法完成特征点定位进而实现心跳分段, 并以距离该心跳周期最近的人工标注类型作为该段标签。由于每次心跳周期均有不同, 为统一后续模型输入, 对分段结果进行采样点统一化处理。根据

心电信号RR间期平均长度和信号采样频率，将心电信号数据样本统一为300个采样点的数据段。

2.2 卷积长短时记忆网络模型

本文提出卷积神经网络自动学习心电信号特征，将输入信号缩减为较小尺寸且长度固定的1维特征向量，再将得到的特征向量输入长短时记忆网络进行训练和测试，实现基于心电信号的心律失常自动分类。CNN通过卷积运算及其特殊的结构能够有效学习数据特征，按阶层结构对输入信息进行平移不变分类。卷积过程中，卷积核重复作用于整个输入的每个感受野，得到输入信号的特征图。输出的特征图会被传递至池化层进行特征选择和信息过滤。池化层使用某一位置相邻输出的总体统计特征代替网络在该位置的输出，减少网络计算量。本文参考VGGNet网络构造框架，结合心电信号自身的性质，设计基于心电信号的1维深度卷积神经网络框架，实现心电信号的自动特征提取。长短时记忆网络是循环神经网络的一种变体，能够有效解决循环神经网络训练过程中出现的梯度消失和梯度爆炸问题，常被用于处理时序信号。在循环神经网络

的结构中增加输入门、遗忘门和输出门。输入门用于学习将哪些信息存储在存储器中，确定需要更新的信息；遗忘门用于了解信息存储的时间长度；输出门用于确定哪些信息可以用于输出。

卷积神经网络提取的信号特征表达能力及可分辨能力强，LSTM能够突出心电信号时序性，记忆信号的内在联系。神经网络模型深度是保证特征抽象性及模型泛化能力的关键，但如果网络模型过深，会出现模型退化问题，因此设计15层的1维卷积神经网络特征学习模型提取心电信号特征，多次实验调整网络参数，使用线性修正单元(Rectified Linear Unit, ReLU)作为卷积神经网络部分的激活函数，并在每个卷积层之后增加批归一化层(Batch Normalization, BN)，防止模型过拟合，得到表达能力及可分辨能力强的信号特征。最终输出长度为38点的1维心电信号特征。将这些特征作为长短时记忆网络分类器的输入，并使用全连接层以及Softmax函数得到不同类别的概率值，实现基于心电信号的心律失常自动分类。本文设计网络模型结构如图2所示。




图1 心电信号预处理




图2 C-LSTM网络结构

在CNN特征提取部分,使用大小为(5,1),滑动步长为1的卷积核自动提取信号形态特征,卷积核个数分别是16到32到64,最终通过卷积核个数为1的卷积层进行特征重组,构成特征图。使用批归一化增加特征向量内部协方差偏移,防止过拟合现象。池化部分均选择大小为2,滑动步长为2的最大池化操作压缩特征向量大小。此外,所有的中间层都使用ReLU作为激活函数。整个卷积部分结束后,心电信号的长度由300×1压缩至38×1的特征向量。卷积长短时记忆网络模型CNN部分的各层详细结构参数如表1所示。

卷积结构中提取的信号空间特征被分解为顺序分量并送到32个单元的LSTM网络中进行时间分析,采用其特殊的门结构,在改善梯度消失和梯度爆炸问题的同时,通过深度学习的方式挖掘心电信号之间的深层次特征并进行学习和映射,帮助模型捕获这些特征向量中存在的时间动态。最后使用全连接层和Softmax函数,根据LSTM单元的输出计算预测概率,完成心电分类。LSTM部分的详细结构参数如表2所示。

2.3 模型训练与分类

网络权重 W 和偏置 b 初始值设置为近似0的随机数,在训练过程中由网络不断调整,以获取数据中存在的有意义的空间信息。从卷积和池化过程中提取的特征被送到重复的长短时记忆网络单元以进行时间分析。使用基于随机梯度下降的自适应矩估计算法(Adaptive Moment Estimation, AME)对模型进行训练,经过偏置校正后,每一次迭代学习率都

有个确定范围,使得参数比较平稳,通过随机梯度下降法(Stochastic Gradient Descent, SGD)更新权重,并使用交叉熵损失函数(Cross Entropy Loss, CEL)式(1)和式(2)计算损失率。学习率固定为0.0001,动量为0.9,批处理大小为20。

$$L(\theta) = -\frac{1}{N} \sum_{k=1}^N \sum_{j=1}^C Y_{k,j} (\log_2(p_{k,j})) + \lambda \|\theta\|^2 \quad (1)$$

$$\theta = \theta + \frac{\partial L(\theta)}{\partial \theta} \quad (2)$$

其中, λ 表示L2范数的正则化项, $Y_{k,j}$ 表示心律失常的类别, c 表示心律失常类别数,个数为5, N 表示训练集样本数, α 为学习率, θ 为模型参数。

最后,仅将长短时记忆网络最后的输出传输到全连接层中,使用Softmax激活函数结合AAMI标准将心电信号分5类,其中Softmax层的5个结点,分别代表N, S, V, F和Q,最终计算得到AAMI标准规定5种类别的概率,计算公式如下

$$p_i(y|x) = \text{softmax}(\omega^x h + b^x) \quad (3)$$

$$\text{softmax}(i) = \frac{e^i}{\sum_j e^j} \quad (4)$$

其中, ω^x, b^x 是Softmax层的权重和偏置, p_i 代表分为第 i 项的概率。

3 实验与结果分析

3.1 数据集

实验数据来自MIT-BIH心律失常数据库,包

表 1 CNN模型的细节和参数

层数	层名称	卷积核大小	卷积核个数	激活函数	步长	参数	输出大小
0	输入	-	-	-	-	-	300×1
1	1维卷积	5×1	16	ReLU	1	96	300×16
2	批归一化	-	-	-	-	128	300×16
3	1维卷积	5×1	16	ReLU	1	1424	300×16
4	批归一化	-	-	-	-	1456	300×16
5	最大池化	2	16	-	2	32	150×16
6	1维卷积	3×1	32	ReLU	1	3024	150×32
7	批归一化	-	-	-	-	3088	150×32
8	1维卷积	3×1	32	ReLU	1	6192	150×32
9	批归一化	-	-	-	-	6256	150×32
10	最大池化	2	32	-	2	64	75×32
11	1维卷积	5×1	64	ReLU	1	16560	75×64
12	批归一化	-	-	-	-	16688	75×64
13	1维卷积	5×1	1	ReLU	1	28800	75×1
14	批归一化	-	-	-	-	28928	75×1
15	最大池化	2	1	-	2	2	38×1

括来自47位受试者的48条带注释的30 min动态心电图信号记录组成, 每条信号采样频率为360 Hz, 包括18种心跳类型的标签注释。

使用美国医疗仪器促进协会制定的AAMI标准进行类型划分, 得到5大类共100700条不对称数据集, 心跳节拍类别划分情况具体见表3。去除数据集中4名使用心脏起搏器患者的心电信号记录, 对剩余信号数据进行预处理, 在保持原有波形形态的情况下得到采样点数统一为300点的数据样本, 如图3所示。其中70%的信号样本用于训练网络模型, 15%用于验证, 最后15%的样本用于测试。训练集、验证集和测试集三者之间相互独立, 没有重复。

表2 LSTM模型的细节和参数

层名称	隐含单元	激活函数	参数
长短时记忆层	32	-	12
全连接	256	ReLU	9996
全连接	5	Softmax	11024

表3 AAMI标准在心电信号分类中描述

AAMI类别	类别数量	MIT-BIH心跳节拍类别
Normal(N)	89972	正常(NOR)
		左束支传导阻塞(LBBB)
		右束支传导阻塞(RBBB)
		房性逸搏(AE)
		结性逸搏(NE)
Supraventricular(S)	2758	房性早搏(AP)
		异常房性早搏(aAP)
		交界性早搏(NP)
		室上性早搏(SP)
		室性早搏(PVC)
Ventricular(V)	7140	室性逸搏(VE)
		起搏心跳(P)
Fusion(F)	800	心室融合心跳(fVN)
Unknown(Q)	30	起搏融合心跳(fPN)
		未分类心跳(U)




图3 各类别心电信号分段结果

3.2 评价方法

为了评估本文模型的性能, 共使用5个统计评价指标, 分别是分类准确度(Acc)、灵敏度(Sen)、特异性(Spe)、正阳性率(PPV)和整体精度(OA), 公式定义分别如式(5)~式(8)所示。并使用测试得到的混淆矩阵进行计算。其中, 准确度指被正确分类的TP与TN占全部样本的比率, 是衡量分类效果最直观的一个指标; 灵敏度即样本中得出阳性检测的样本占样本总数的百分比, 灵敏度越高表示发生漏诊的比率越低; 特异性也叫真阴性率, 是指被分类为阴性样本数与实际阴性样本数的比率, 特异性越高表示发生误诊的比率越低; 正阳性率是预测的全部阳性例数中, 真阳性所占的比例, 反映样本属于该类别的可能性, 正阳性率越高表示发生误诊的比例越低。最后, 用OA衡量这些算法对心律失常的分类能力, 计算测试集总体分类精度。

$$\text{Acc}(\%) = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{TN} + \text{FN}} \times 100\% \quad (5)$$

$$\text{Sen}(\%) = \frac{\text{TP}}{\text{TP} + \text{FN}} \times 100\% \quad (6)$$

$$\text{Spe}(\%) = \frac{\text{TN}}{\text{TN} + \text{FP}} \times 100\% \quad (7)$$

$$\text{PPV}(\%) = \frac{\text{TP}}{\text{TP} + \text{FP}} \times 100\% \quad (8)$$

其中TP为真阳性, 表示正确分类的个数; FN为假阳性, 表示错误分类的个数; TN为真阴性, 表示不属于某种心跳但被分为该类的个数; FP为假阴性, 表示属于某种心跳但被错误分类的个数。

3.3 结果分析

本文使用基于Python语言的深度学习框架tensorflow实现卷积长短时记忆网络模型, 所有实验研究均在具有Intel(R)Core(TM)i7-8550U 1.8 GHz 1.99 GHz CPU处理器、Windows10操作系统、8 GB内存和NVIDIA GeForce MX150显卡的计算机上进行。卷积神经网络方面参考VGG网络模型多层卷积连接池化的结构, 学习大尺寸心电信号中的特征, 压缩信号大小, 提高后续训练效率。

图4给出了CNN特征提取后得到的心电信号形态特征。将CNN压缩后的信号作为LSTM网络的输入，捕获这些特征信号中的时间动态。最后通过全连接层根据长短时记忆网络单元的输出计算预测概率，完成心律失常分类，并准备了两种不同的网络结构进行对比和评估。两种网络之间的唯一区别在于输入信号不同。第1种LSTM网络使用原始心电信号作为网络输入；第2种LSTM网络使用由卷积神经网络自动学习得到的信号特征作为网络输入。这样做的目的是评估CNN作为特征提取器的效果，以及方便二者进行对比分析。网络在训练阶段进行10000次迭代，并且使用测试数据评估训练模型的性能。

图5分别给出了使用原始心电信号以及将卷积神经网络作为特征提取器的情况下，使用长短时记忆网络完成10000次迭代的训练和验证性能。可以看出，用于分类的两个网络的性能相似。使用具有300个采样点的原始心电信号作为长短时记忆网络的输入时，在10000次迭代过程中实现了最高99.13%的验证性能，而使用卷积特征提取的网络在同一时期内实现了最高99.17%的验证。二者都没有过拟合的问题，两个模型都表现出很高的训练性能。并且，在将原始心电信号作为网络输入数据时，长短时记忆网络模型共训练13772 s，约3.8 h；而本文提出的卷积长短时记忆网络模型，由于使用卷积神经网络作为特征提取器，将300个采样点的

原始心电信号压缩至大小为38个采样点的网络输入，在训练阶段总训练时长为1561 s，约0.43 h。可以看出，二者在训练准确率上并没有很大差距，都达到99.00%以上，这说明本文提出的卷积神经网络特征提取器有效压缩心电信号的维度。并且，极大缩短了长短时记忆网络的训练时间，降低了心电信号自动分类模型的时间成本。

将训练好的网络模型用于测试集，表4分别给出了两种不同输入网络模型各类别评价参数。可以看到，相比其他类别，模型在F类和Q类中评价参数较低，这可能是由于这两类的样本数量较少且在心电图上，FVN是由于两个节律点发出的冲动同时激动心室的一部分形成的心室综合波，而室性早搏是在窦房结冲动尚未抵达心室之前，由心室中的任何一个部位或室间隔的异位节律点提前发出电冲动引起心室的除极。因此，二者可能产生混淆。另外可以看到，本文提出的C-LSTM模型在Sen和PPV评价指标上相比LSTM模型具有明显提高，且C-LSTM的各类评估参数平均值均高于LSTM模型，这进一步说明了本文模型的有效性，降低了实际分类中漏诊和误诊发生的比率。并且在测试时间上，LSTM网络的平均测试持续时间为37.6 s，而C-LSTM模型的平均测试持续时间仅4.2 s。进一步说明本模型有效缩短基于心电信号的心律失常自动分类时间，模型效率高，计算负担小。

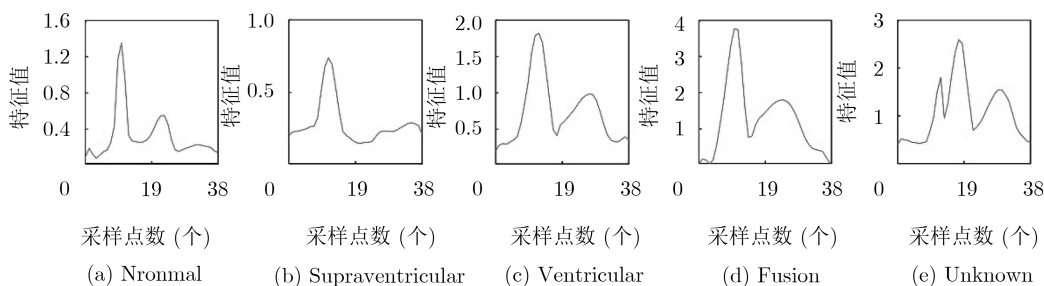


图4 CNN提取到的信号特征




图5 网络训练和验证性能图

图6显示了测试集的混淆矩阵。前者网络在15105个测试数据上的分类准确率为99.14%；而本文提出的C-LSTM模型在测试数据上的分类准确率达到99.23%，明显高于前者。仿真实验数据集中训练集、验证集和测试集三者之间无重复数据，证明了本文方法对心电信号诊断具有很强的适应性。

将所提出的C-LSTM模型与先前ECG心律失常分类工作的性能进行对比，具体见表5。由于这些

工作具有不同数量的测试集和心律失常类型，因此直接比较是不公平的。然而，本文提出的C-LSTM模型与其他先前的工作相比成功实现心电信号的自动分类。并且，本文模型同时具有卷积神经网络和长短时记忆网络的混合系统实现数据的循环连接和密集连接。使用卷积操作有效提取心电信号特征，压缩信号大小，从而降低模型训练时间成本并获得较高的分类准确率。

表4 LSTM网络和C-LSTM网络测试集的相关评价参数(%)

网络	评价参数	模型类别				
		N	S	V	F	Q
LSTM	Acc	99.54	99.62	99.44	99.71	99.97
	Sen	99.87	91.06	95.66	80.19	0
	Spe	96.91	99.86	99.76	99.58	99.99
	PPV	99.61	95.09	97.00	78.70	0.00
C-LSTM	Acc	99.52	99.61	99.51	99.84	99.97
	Sen	99.78	92.11	96.63	88.52	0
	Spe	98.36	99.83	99.73	99.93	99.99
	PPV	99.68	94.08	96.45	91.53	0.00

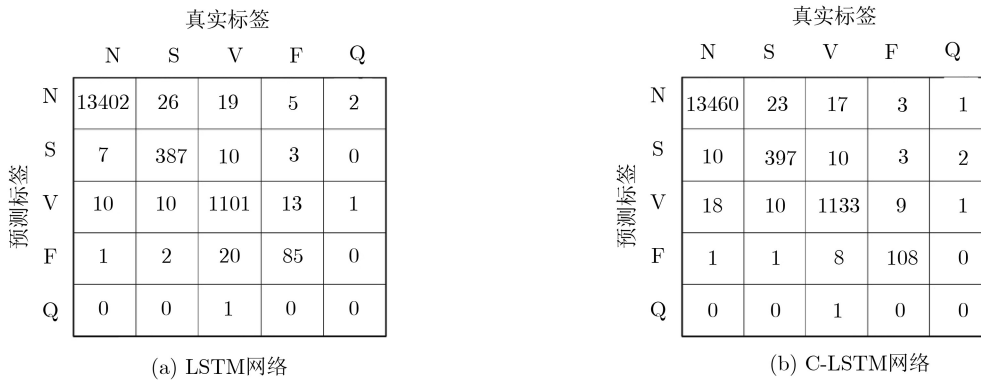


图6 网络测试集混淆矩阵

表5 自动检测心律失常分类结果性能比较

研究	类型	分类器	信号长度	性能(%)			
				Acc	Sen	Spe	PPV
文献[19]	4	FFNN	250 samples (0.69 s)	96.94	97.78	96.31	-
文献[17]	17	KNN	360 samples (1.00 s)	97.00	97.10	96.90	-
文献[18]	5	SVM+RBF	200 samples (0.56 s)	98.91	98.91	97.85	-
文献[4]	14	NPE+SVM	300 samples (0.83 s)	98.51	98.51	-	98.51
文献[11]	5	CNN	360 samples (1.00 s)	94.03	96.71	91.54	97.86
文献[20]	4	SVM	8×1071	98.39	96.86	98.92	96.85
文献[12]	5	CNN	73×73	98.42	72.06	97.83	65.91
文献[15]	5	FCMDBN	200 samples (0.56 s)	96.54	94.55	93.31	93.91
文献[14]	2	CNN+RNN	211×24	95.76	87.85	87.85	94.99
本文方法	5	LSTM	300 sample (0.83 s)	99.14	91.70	99.22	92.60
		C-LSTM	300 → 38 samples(0.83 s)→(0.12 s)	99.23	94.26	99.57	95.44

4 结束语

心脏异常早期诊断能够降低心血管疾病的发病率, 辅助临床医生进行早期诊断、治疗。本文所提卷积长短时记忆网络模型实现基于心电信号的心律失常自动分类, 综合卷积神经网络和长短时记忆网络的优势, 成功实现心电信号自动分类任务, 且有效解决了深度神经网络模型训练时间长的问题。在仿真实验中, 分别使用原始和卷积神经网络压缩后的心电信号作为长短时记忆网络的输入数据, 网络的分类准确率分别是99.14%和99.23%, 训练时长分别是3.8 h和0.43 h。这表明本文模型不仅降低了便携式移动健康监测等设备的硬件成本, 加强CPU计算力, 还有助于心率失常的实时检测, 提高网络分类性能。在未来的工作中, 可深入研究将此模型用于可变长度的心跳信号并考虑迁移学习方法为心电信号自动分类任务带来的新思路。

参 考 文 献

- [1] World Health Organization. Cardiovascular diseases[EB/OL]. https://www.who.int/health-topics/cardiovascular-diseases/#tab=tab_1, 2017.
- [2] YE Can, KUMAR B V K V, and COIMBRA M T. Heartbeat classification using morphological and dynamic features of ECG signals[J]. *IEEE Transactions on Biomedical Engineering*, 2012, 59(10): 2930–2941. doi: 10.1109/tbme.2012.2213253.
- [3] YILDIRIM Ö. ECG beat detection and classification system using wavelet transform and online sequential ELM[J]. *Journal of Mechanics in Medicine and Biology*, 2019, 19(1): 1940008. doi: 10.1142/S0219519419400086.
- [4] 高兴姣, 李智, 陈珊珊, 等. 基于近邻保持嵌入算法的心律失常心拍分类[J]. *生物医学工程学杂志*, 2017, 34(1): 1–6. doi: 10.7507/1001-5515.201605045.
GAO Xingjiao, LI Zhi, CHEN Shanshan, *et al.* Arrhythmia heartbeats classification based on neighborhood preserving embedding algorithm[J]. *Journal of Biomedical Engineering*, 2017, 34(1): 1–6. doi: 10.7507/1001-5515.201605045.
- [5] AHMED R and ARAFAT S. Cardiac arrhythmia classification using hierarchical classification model[C]. The 6th International Conference on Computer Science and Information Technology (CSIT), Amman, Jordan, 2014: 203–207. doi: 10.1109/CSIT.2014.6806001.
- [6] BALOUCHESTANI M, SUGAVANESWARAN L, and KRISHNAN S. Advanced K-means clustering algorithm for large ECG data sets based on K-SVD approach[C]. The 9th International Symposium on Communication Systems, Networks & Digital Sign (CSNDSP), Manchester, UK, 2014: 177–182. doi: 10.1109/CSNDSP.2014.6923820.
- [7] LI Duan, ZHANG Hongxin, and ZHANG Mingming. Wavelet de-noising and genetic algorithm-based least squares twin SVM for classification of arrhythmias[J]. *Circuits, Systems, and Signal Processing*, 2017, 36(7): 2828–2846. doi: 10.1007/s00034-016-0439-8.
- [8] YIN Xi and LIU Xiaoming. Multi-task convolutional neural network for pose-invariant face recognition[J]. *IEEE Transactions on Image Processing*, 2018, 27(2): 964–975. doi: 10.1109/TIP.2017.2765830.
- [9] 王斐, 吴仕超, 刘少林, 等. 基于脑电信号深度迁移学习的驾驶疲劳检测[J]. *电子与信息学报*, 2019, 41(9): 2264–2272. doi: 10.11999/JEIT180900.
WANG Fei, WU Shichao, LIU Shaolin, *et al.* Driver fatigue detection through deep transfer learning in an electroencephalogram-based system[J]. *Journal of Electronics & Information Technology*, 2019, 41(9): 2264–2272. doi: 10.11999/JEIT180900.
- [10] MENG Huanhuan and ZHANG Yue. Classification of electrocardiogram signals with deep belief networks[C]. The 17th International Conference on Computational Science and Engineering, Chengdu, China, 2014: 7–12. doi: 10.1109/CSE.2014.36.
- [11] 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. doi: 10.1016/j.complbiomed.2017.08.022.
- [12] ZHAI Xiaolong and TIN C. Automated ECG classification using dual heartbeat coupling based on convolutional neural network[J]. *IEEE Access*, 2018, 6: 27465–27472. doi: 10.1109/ACCESS.2018.2833841.
- [13] CHENG Maowei, SORI W J, JIANG Feng, *et al.* Recurrent neural network based classification of ecg signal features for obstruction of sleep apnea detection[C]. 2017 IEEE International Conference on Computational Science and Engineering (CSE) and IEEE International Conference on Embedded and Ubiquitous Computing (EUC), Guangzhou, China, 2017, 199–202. doi: 10.1109/CSE-EUC.2017.220.
- [14] TAN J H, HAGIWARA Y, PANG W, *et al.* Application of stacked convolutional and long short-term memory network for accurate identification of CAD ECG signals[J]. *Computers in Biology and Medicine*, 2018, 94: 19–26. doi: 10.1016/j.complbiomed.2017.12.023.
- [15] 吴志勇, 丁香乾, 许晓伟, 等. 基于深度学习和模糊C均值的心电信号分类方法[J]. *自动化学报*, 2018, 44(10): 1913–1920. doi: 10.16383/j.aas.2018.c170417.
WU Zhiyong, DING Xiangqian, XU Xiaowei, *et al.* A method for ECG classification using deep learning and fuzzy C-means[J]. *Acta Automatica Sinica*, 2018, 44(10): 1913–1920. doi: 10.16383/j.aas.2018.c170417.
- [16] HANNUN A Y, RAJPURKAR P, HAGHPANAHI M, *et al.*

- Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network[J]. *Nature Medicine*, 2019, 25(1): 65–69. doi: [10.1038/s41591-018-0268-3](https://doi.org/10.1038/s41591-018-0268-3).
- [17] PARK J, LEE K, and KANG K. Arrhythmia detection from heartbeat using k-nearest neighbor classifier[C]. 2013 IEEE International Conference on Bioinformatics and Biomedicine, Shanghai, China, 2013: 15–22. doi: [10.1109/BIBM.2013.6732594](https://doi.org/10.1109/BIBM.2013.6732594).
- [18] ELHAJ F A, SALIM N, HARRIS A R, *et al.* Arrhythmia recognition and classification using combined linear and nonlinear features of ECG signals[J]. *Computer Methods and Programs in Biomedicine*, 2016, 127: 52–63. doi: [10.1016/j.cmpb.2015.12.024](https://doi.org/10.1016/j.cmpb.2015.12.024).
- [19] GÜLER I and ÜBEYLI E D. ECG beat classifier designed by combined neural network model[J]. *Pattern Recognition*, 2005, 38(2): 199–208. doi: [10.1016/j.patcog.2004.06.009](https://doi.org/10.1016/j.patcog.2004.06.009).
- [20] 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. doi: [10.1016/j.measurement.2017.05.022](https://doi.org/10.1016/j.measurement.2017.05.022).
- 柯 丽: 女, 1977年生, 博士, 教授, 博士生导师, 研究方向为生物电工与阻抗成像技术.
- 王丹妮: 女, 1995年生, 硕士生, 研究方向为医学信号处理与分析.
- 杜 强: 男, 1975年生, 博士, 讲师, 研究方向为生物医学信号检测与处理.
- 姜楚迪: 女, 1996年生, 硕士生, 研究方向为医学电磁工程及医疗仪器.

责任编辑: 阮 望