

# 基于 BiLSTM 和多分支 CNN 的心律失常自动分类

李怀东,吴腾

(福州大学 机械工程及自动化学院,福建 福州 350108)

**摘要:**针对传统心电信号( ECG)分类中卷积神经网络(CNN)模型的细节特征缺失问题,使用多支路的 CNN 提取更深层次的特征。考虑到 ECG 具有时序性的特点,融合双向长短时神经网络(BiLSTM)模型,提出一种基于 BiLSTM 和多分支 CNN 的分类方法。该方法先对数据库的心电数据进行心拍分割,然后送入有 3 条分支的 CNN 和 BiLSTM 组成的网络模型进行训练,最后对模型在测试集上进行评价。实验结果表明:该方法的分类效果良好,在对 S 和 V 类分类上优于其他深度学习方法。

**关键词:**心电信号;卷积神经网络;双向长短时记忆神经网络;多分支

**中图分类号:**TP183 **文献标志码:**B **文章编号:**1671-5276(2022)06-0102-04

## Automatic Classification of Arrhythmias Based on BiLSTM and Multi-branch CNN

LI Huaidong, WU Teng

(School of Mechanical Engineering and Automation, Fuzhou University, Fuzhou 350108, China)

**Abstract:** In the light of the missing details of convolutional neural network (CNN) model in traditional (ECG) signal classification, multi-branch CNN was applied to extract deeper features. In consideration of the characteristic of ECG with timing, a classification method based on BiLSTM and multi-branch CNN is proposed by integrating BiLSTM model. With this method, ECG data from MIT-BIH were first segmented by heart beat, and then sent to the network model consisting of CNN and BiLSTM with three branches for training. Evaluation on the test set was conducted. Experimental results show that the proposed method has good classification effect and is superior to other deep learning methods in classification of S and V classes.

**Keywords:** ECG signal; convolutional neural network; bidirectional long short-term memory networks; multi-branch

## 0 引言

根据《中国心血管健康与疾病报告 2019》<sup>[1]</sup>,近年来,我国的心血管疾病死亡率仍旧居于首位,每 5 例死亡者中有 2 例死于心血管病。报告强调,为降低日益加重的心血管疾病负担,一方面仍要强调提高医疗水平,改善医疗质量,另一方面最重要的是加强对心血管危险因素的控制,预防心血管疾病的发生。

心电信号是临床用于诊断病人心脏健康状态的一种综合工具,具有无创、设备能耗低和易获取等特点,所以在各种心律失常检测以及心脏病病理分析中都发挥了巨大的作用。心律失常是指心脏出现异常活动或行为的情景,它是心血管疾病预防的关键。在过去十年里,发展了许多基于信号处理技术的自动心跳分类方法,主要包括两个步骤:特征提取和分类。心电信号的自动分类流程首先通过对心电图中的特征系数进行特征提取,突出异常和正常特征的区别,然后再利用相应的分类器对特征进行分类来达到识别心律目的。其中,心律失常的分类方法主要有:支持向量机<sup>[2]</sup>、神经网络<sup>[3]</sup>、决策树(CT)<sup>[4]</sup>和加权条件随机域(CRF)<sup>[5]</sup>。近年来,随着深度学习(deep learning)的大热,越来越多的人将其应用到了心电信号的分类

中<sup>[6-7]</sup>。基于深度学习的分类方法无需对心电信号特征提取,能够根据原始的信号对其所属的类别直接进行分类,具有高效、便捷和精准的特点。

## 1 CNN 和 BiLSTM 算法

### 1.1 卷积神经网络理论

卷积神经网络由几个卷积层组成,每层卷积层之后通常是接池化层,如图 1 所示。在卷积层中,每一隐藏层中的每一个神经元都连接到前一隐藏层神经元的一个小区域,即感受域。其中,每个神经元学习一组权重,而每层学习一个总体偏差。随后,滑动卷积窗口,下一隐藏层的神经元根据窗口的位置学习相应的权值。

这个过程在数学中可以表示为

$$a_j^l = \sigma \left( \sum_{k=1}^n \omega_k^l a_{j+k-1}^{l-1} + b^l \right) = \sigma \left( \omega^l a_j^{l-1} + b^l \right) \quad (1)$$

式中: $a_j^l$ 表示第  $l$  层的第  $j$  个神经元的输出; $\sigma$ 是激活函数; $b^l$ 为该层的整体偏置; $n$ 为卷积核的大小; $\omega^l = [\omega_1^l \ \omega_2^l \ \dots \ \omega_n^l]$ 是该层的共享权值向量,用于对网络中特征进行加权; $a_j^{l-1} = [a_j^{l-1} \ a_{j+1}^{l-1} \ \dots \ a_{j+k-1}^{l-1}]^T$ 是上一

第一作者简介:李怀东(1997—),男,福建泉州人,硕士研究生,研究方向为心电信号检测、重构和分类。

隐藏层的输出。




图1 卷积神经网络结构

## 1.2 BiLSTM 理论

对于信号而言,往往具有很强的时序性,而在时序特征提取的能力上,CNN 是不如循环神经网络(RNN)的。长短时记忆神经网络(LSTM)是一种特殊的RNN。与RNN相同,LSTM也采用了重复模块链的形式,但不同之处在于重复模块的结构不同。RNN的重复模块只有一层,而LSTM有4层,它们以一种特殊的方式相互作用。其数学表达式如下:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

$$h_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \cdot \tanh(C_t) \quad (5)$$

式中: $x_t$ 是输入序列; $h_{t-1}$ 是上一隐藏层的输出; $b_f$ 、 $b_i$ 和 $b_c$ 分别表示遗忘门、输入门和输出门的偏置; $W_f$ 、 $W_i$ 和 $W_o$ 分别表示遗忘门、输入门和输出门的权重; $W_c$ 为当前单元的权重; $C_t$ 是当前细胞的记忆单元。其中,权重采用随机初始化,而偏置初始化为0。

传统的LSTM有一定的局限性,只能实现单向传输。它从前面到后面提取数据特征的能力较强,但对从后往前的信息识别性较差。双向LSTM(BiLSTM)很好地解决了这个问题。双向层实际上是由两个方向相反的LSTM层组成:前向LSTM和后向LSTM。在每个时间步中,前向LSTM的输出总结了之前所有时间步的局部特征,后向LSTM的输出也总结了后续所有时间步的局部特征。将两个LSTM层在某一时刻的局部输出进行汇总后,通过激活函数对其进行非线性处理。因此,提取的特征可以更好地反映数据信息,达到更好的特征提取效果。

## 2 心律失常分类实验

### 2.1 实验数据来源及预处理

本文实验数据选自美国麻省理工学院所提供的

MIT-BIH 心律失常的数据库<sup>[8]</sup>。该数据库包含 48 条双导联动态心电信号记录,记录来自于心律失常实验室的 47 名受试者(记录 201 和 202 来自同一男性),采样频率为 360 Hz。本文采用导联 I 心电数据作为实验样本,根据数据中的 QRS 波位置取波前 0.4 s,波后 0.5 s,再下采样成 320 采样点的心拍作为输入数据。分类标准按照美国医疗仪器促进协会(AAMI)将原始的 MIT-BIH 的标签重新分成:正常或者束支传导阻滞节拍(N)、室上性异常节拍(S)、心室异常节拍(V)、融合节拍(F)、未能分类节拍(Q)等 5 类。并根据 7 : 3 的比例将数据集划分成训练和测试集。原始标签和重新分类的 AAMI 标签如表 1 所示。

表 1 AAMI 标签与 MIT-BIH 标签对照表

AAMI 标签	MIT-BIH 标签	心跳类别
	NOR	正常搏动
	LBBB	左束支阻滞跳动
N	RBBB	右束支阻滞跳动
	AE	心房逸搏
	NE	节点逸搏
	AP	房性早搏
S	aAP	异常房性早搏
	NP	节点早搏
	SP	室上性早搏
V	PVC	室性早搏
	VE	室性逸搏
F	fVN	心室融合心跳
Q	P	节奏心拍
	U	未分类心跳

### 2.2 评估标准

为全面评估研究方法对心拍的分类结果,本实验采用混淆矩阵,主要包括三大评定指标:敏感度(Se)、精确度(Pre)、F1 分数。

$$S_e = \frac{TP}{TP+FN} \quad (6)$$

$$P_{re} = \frac{TP}{TP+FP} \quad (7)$$

$$F1 = \frac{2 \times P_{re} \times S_e}{P_{re} + S_e} \quad (8)$$

式中:真阳性 TP 表示正样本被预测为正样本的数目;假阴性 FN 表示正样本被预测为负样本的数目;假阳性 FP 表示负样本被预测为正样本的数目。

### 2.3 模型搭建

如图 2 所示,本文所搭建的神经网络由三支的卷积神经网络后接一层 BiLSTM 及两层多层感知机(MLP)构成。其中,每条分支由两层卷积神经网络组成,而每层 CNN 所使用的卷积核都不相同,这有助于在不同的空间尺度上提取信号的细节特征。每层卷积层后接一层批量归一层(BN)和激活层,所使用的激活函数为 ReLu,且步长均为

1. 对于每支路的最后一层卷积层后接步长为 2 的池化层,用于减小网络结构参数,加快收敛。在卷积网络结束后,先对每支路卷积进行拼接,然后输入一层神经元个数为 32 的 BiLSTM,用于提取时序特征。最后接两层 MLP,用于对分类结果进一步的细化和分类,最后一层 MLP 所采用的激活函数为 Softmax。详细的参数如表 2 所示。

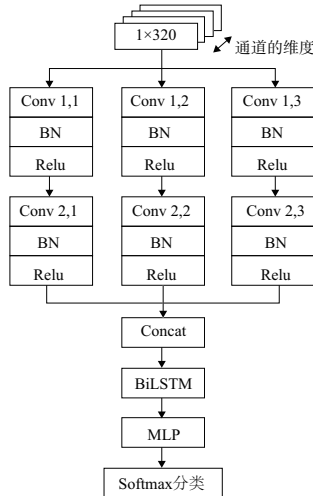


图 2 本文所使用的神经网络结构

表 2 本文所使用模型的细节参数

层名	输出尺寸	卷积核尺寸	填充类型
Input	[320,1]	—	—
Conv 1,1	[320,32]	[1,5]	SAME
Conv 1,2	[320,32]	[1,7]	SAME
Conv 1,3	[320,32]	[1,9]	SAME
Conv 2,1	[320,32]	[1,3]	SAME
Pool 2,1	[160,32]	—	—
Conv 2,2	[320,32]	[1,5]	SAME
Pool 2,2	[160,32]	—	—
Conv 2,3	[320,32]	[1,7]	SAME
Pool 2,3	[160,32]	—	—
Concatenate	[160,96]	—	—
BiLSTM	[160,64]	—	—
Flatten	[10 240]	—	—
MLP1	[32]	—	—
MLP2	[5]	—	—

### 3 实验结果与讨论

本实验模型在 Intel i7-8750H CPU、NVIDIA GTX 1060 上训练,内存为 16 GB,使用基于 python3.6 的 tensorflow2.1 框架。心拍的分割与数据集的制作在 jupyter 上实现,其中训练集和测试集分别有 70 479 和 30 208 个样本,并在训练阶段使用五折交叉验证。五折交叉验证通过将训练集平均分成 5 个不同训练组,取其中 1 份作为验

证集,剩下 4 份作为训练集。在每次训练结束后轮换训练和验证集,5 次轮换后平均结果来降低方差,因此其结果对数据集划分的敏感性较低,具有较强的稳定性。训练过程中所使用的优化器为 adam,学习率为 0.000 1,每批次输入 32 个样本,迭代的次数为 100。

测试了传统 CNN、多分支 CNN 及本文所提出的基于 BiLSTM 和多分支 CNN 的模型的训练与验证准确率,其结果如图 3 所示(本刊为黑白印刷,如有疑问请咨询作者)。从图 3 可以看出,无论是在训练还是测试阶段,本文提出的模型在准确率都高于其他的模型,说明该模型对分类的性能有一定的提升。在第 30 次迭代后训练和验证集曲线平稳,没有发生过拟合现象。





图 3 训练和验证集准确率的变化

使用训练好的模型对测试集进行分类,得到混淆矩阵如表 3 所示。其中列是模型的预测值,行表示样本的真实值,对角线表示正确分类的结果。可以看出模型在测试集上表现良好,对于每一类基本都将心拍成功分类,特别是对于 N、V、F 这三个类别表现尤为突出,这三类在 F1 得分上分别高达 99.5%、97.1%、97.7%,而对于 Q 类,训练和测试集仅有 10 个和 5 个样本,但在样本量少的情况下,仍有 1 个样本被分类成功,说明模型充分考虑到样本间的平衡性。

表 3 分类结果的混淆矩阵表示

真实值	预测值				
	N 类	S 类	V 类	F 类	Q 类
N 类	29 982	53	43	1	2
S 类	121	702	11	0	0
V 类	51	11	2 041	0	0
F 类	4	2	4	231	0
Q 类	2	0	2	0	1

本文研究方法与近年来国外在 MIT-BIH 数据库上的心电信号自动识别方法进行对比,主要比较 S 和 V 两类。根据 AAMI 标准,S 和 V 类的识别分类更具有临床意义,其结果如表 4 所示,最好效果已加粗。可以看出,本文的方法在 V 和 S 类上虽然 Pre 值略低,但是效果基本持平,而且 Sen 和 F1 值高于其他文献。作为综合指标,S 和 V 类的 F1 相较于其他文献最好的结果分别提高了 2.3 和 0.9。说明本文方法能在不同层面上更深提取 ECG 的特征,以此来达到更好的分类精度效果。

表 4 本文与其他方法比较 单位: %

论文方法	V 类			S 类		
	Sen	Pre	F1	Sen	Pre	F1
文献[9]	93.8	92.4	93.1	76.8	74.0	75.4
文献[10]	93.0	<b>98.2</b>	95.5	66.9	<b>95.7</b>	78.7
文献[11]	95.4	97.1	96.2	81.1	90.0	85.3
本文方法	<b>97.1</b>	97.1	<b>97.1</b>	<b>84.2</b>	91.4	<b>87.6</b>

## 4 结语

本文针对传统 CNN 模型对细节特征方面提取的不足,使用多支路的 CNN 来提取更深层次的特征,同时考虑到 ECG 作为时序信号,结合 BiLSTM 模型对序列信号优势特点,将其应用在网络模型的搭建中,分析和讨论了在训练过程中该模型的训练和验证准确率变化情况。模型在测试集上的分类效果,重点比较了该模型与其他论文的 Sen、Pre 和 F1 值。实验结果表明:在训练阶段,该模型无论在准确率还是拟合效果方面都优于之前的传统模型;在测试阶段,模型对每类的分类在不同指标上都有良好的效果;与其他论文相比,在细节与综合得分上持平或者高于其他论文模型。综上可知,该模型在心电信号的自动分类上具有良好的应用前景。

### 参考文献:

[1] 国家心血管病中心. 中国心血管健康与疾病报告 2019[J].

心肺血管病杂志,2020,39(10):1157-1162.

- [2] MONDÉJAR-GUERRA V, NOVO J, ROUCO J, et al. Heartbeat classification fusing temporal and morphological information of ECGs via ensemble of classifiers [J]. Biomedical Signal Processing and Control, 2019, 47: 41-48.
- [3] MATHEWS S M, KAMBHAMETTU C, BARNER K E. A novel application of deep learning for single-lead ECG classification [J]. Computers in Biology and Medicine, 2018, 99: 53-62.
- [4] MARTIS R J, ACHARYA U R, ADELI H, et al. Computer aided diagnosis of atrial arrhythmia using dimensionality reduction methods on transform domain representation [J]. Biomedical Signal Processing and Control, 2014, 13: 295-305.
- [5] JIANG W, KONG S G. Block-based neural networks for personalized ECG signal classification [J]. IEEE Transactions on Neural Networks, 2007, 18(6): 1750-1761.
- [6] ACHARYA U R, FUJITA H, LIH O S, et al. Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network [J]. Information Sciences, 2017, 405: 81-90.
- [7] HE R N, LIU Y, WANG K Q, et al. Automatic cardiac arrhythmia classification using combination of deep residual network and bidirectional LSTM [J]. IEEE Access, 2019(7): 102119-102135.
- [8] MOODY G B, MARK R G. The impact of the MIT-BIH arrhythmia database [J]. IEEE Engineering in Medicine and Biology Magazine, 2001, 20(3): 45-50.
- [9] ZHAI X L, TIN C. Automated ECG classification using dual heartbeat coupling based on convolutional neural network [J]. IEEE Access, 2018(6): 27465-27472.
- [10] 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.
- [11] LI F T, WU J Q, JIA M H, et al. Automated heartbeat classification exploiting convolutional neural network with channel-wise attention [J]. IEEE Access, 2019(7): 122955-122963.

收稿日期: 2021-08-18

### (上接第 44 页)

机械工程知识、艺术美学和创新设计复合作用的翅膀,使未来的工业产品设计师们翱翔得更高更远。

### 参考文献:

- [1] 陈桃珍. 高职传媒类专业群产教融合课程建设“部门+项目”教学组织设计[J]. 当代教育论坛, 2017(3): 75-82.
- [2] 陈金亮, 赵锋, 邓哈. 工业设计专业机械设计基础课程教学改革研究[J]. 工业设计, 2018(1): 25-26.
- [3] 胡海星, 张春霞, 张春艳. 基于职业能力开发的高职实训教学评价模型及应用研究[J]. 当代教育论坛, 2015(4): 115-120.
- [4] 刘力夫. 工业设计专业“机械设计基础”课程教学改革与探索[J]. 机械设计, 2018, 35(增刊 2): 413-414.
- [5] 韩筠. 创新教与学 推动新时期高校教学改革[J]. 中国大学教学, 2017(6): 11-14.
- [6] 岳樱泽, 杨恒. 基于终身教育视角下高职院校学生关键能力的培养[J]. 当代教育论坛, 2016(5): 89-94.
- [7] 李桂霞, 钟建珍. 对构建合理的高职教育课程体系的探

讨[J]. 中国高教研究, 2007(6): 58-59.

- [8] 葛丽娜. 以学生为中心教育方式的思考与实践[J]. 现代计算机(专业版), 2016(15): 11-14.
- [9] 彭娟, 汪杉. 工业设计专业基础课程教学方式的反思与创新[J]. 黑龙江科技信息, 2016(29): 8.
- [10] 张冬梅. 工业设计专业“造型材料与工艺”课程教学改革初探[J]. 焦作大学学报, 2016, 30(3): 100-102.
- [11] MENG Q, LI F Y, ZHOU L R, et al. A rapid life cycle assessment method based on green features in supporting conceptual design [J]. International Journal of Precision Engineering and Manufacturing-Green Technology, 2015, 2(2): 189-196.
- [12] BRANCO P T B S, ALVIM-FERRAZ M C M, MARTINS F G, et al. Indoor air quality in urban nurseries at Porto City: particulate matter assessment [J]. Atmospheric Environment, 2014, 84: 133-143.

收稿日期: 2022-08-03