

DOI: 10.19951/j.cnki.1672-9331.20230303001

文章编号:1672-9331(2024)06-0142-10

引用格式:林鸣放,席燕辉.基于小波变换和Inception网络的心跳分类[J].长沙理工大学学报(自然科学版),2024,21(6):142-151.

Citation: LIN Mingfang, XI Yanhui. Heartbeat classification based on wavelet transform and Inception network [J]. J Changsha Univ Sci Tech (Nat Sci), 2024, 21(6): 142-151.

基于小波变换和Inception网络的心跳分类

林鸣放,席燕辉

(长沙理工大学 电气与信息工程学院,湖南 长沙 410114)

摘要:【目的】针对临床专业人士对心电图进行逐拍分析诊断时存在的耗时耗力问题,本文提出了一种基于预训练的Inception网络心电图自动识别方法。【方法】首先使用墨西哥小波变换将心电图从时域转换到时频域,提取心跳信号的时域和频域信息,然后利用Inception网络对心跳时频图进行自动诊断识别。训练中采用随机梯度下降算法对模型进行优化。【结果】为验证所提方法的有效性,在公开心律失常数据集中选取5种心跳数据进行测试。结果表明,本文算法在阳性预测值、召回率和准确率等指标都取得了很好的成绩,且在相同试验条件下,收敛更快,其准确度比预训练好的残差网络和视觉几何群网络的更高。【结论】采用墨西哥小波基函数能更好地表征单个心跳形状,而采用端到端的Inception模型能将不同宽度心跳信号特征矩阵按深度进行拼接,提取更丰富的特征。

关键词:心电图;心跳分类;Inception网络;小波变换

中图分类号:TP391

文献标志码:A

Heartbeat classification based on wavelet transform and Inception network

LIN Mingfang, XI Yanhui

(School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha 410114, China)

Abstract: [Purposes] In clinical practice, professionals need to analyze and diagnose the electrocardiograph (ECG) beat by beat, which is time-consuming and energy-consuming. To address this issue, an automatic ECG identification method based on a pre-trained Inception network was proposed. [Methods] Firstly, the Mexican wavelet transform was used to convert the ECG from the time domain to the time-frequency domain and extract the time domain and frequency domain information of heartbeat signals. Secondly, the Inception network was utilized to automatically diagnose and identify time-frequency graphs of heartbeats, and the stochastic gradient descent momentum (SGDM) algorithm was adopted for model optimization during the training. [Findings] In order to verify the effectiveness of the proposed method, five types of heartbeat data from the public arrhythmia database were selected, and experimental results show that the proposed algorithm performs well in indicators such as positive predictive value, recall rate, and accuracy, and it has higher precision and faster convergence compared with the pre-trained residual networks and visual geometry group networks under the same experimental

收稿日期:2023-03-03;修回日期:2023-03-31;接受日期:2023-04-01

基金项目:国家自然科学基金面上项目(52277078);湖南省教育厅重点项目(21A0210)

通信作者:席燕辉(1979—)(ORCID:0000-0001-8598-4771),女,教授,主要从事复杂系统与建模、配电网和输电线路故障检测与分类、心律失常检测和分类等方面的研究。E-mail:xiyanhui@126.com

投稿网址: <http://cslgxbzk.csust.edu.cn/cslgdxxbzk/home>

conditions. [Conclusions] The Mexican wavelet basis function can better characterize the shape of a single heartbeat, and the end-to-end Inception model can concatenate the heartbeat signal feature matrices with different widths according to the depth and extract richer features.

Key words: electrocardiogram; heartbeat classification; Inception network; wavelet transform

Foundation items: Project (52277078) supported by the National Natural Science Foundation of China; Project (21A0210) supported by Key Projects of Hunan Provincial Department of Education

Corresponding author: XI Yanhui (1979—) (ORCID: 0000-0001-8598-4771), female, associated professor, research interest: complex systems and modeling, distribution network and transmission line fault detection and classification, arrhythmia detection and classification. E-mail: xiyanhui@126.com

0 引言

心律失常是心跳频率发生紊乱、心跳不规律、心脏的心房和心室不协调的症状,一般与心力衰竭、冠心病和高血压等疾病有密切联系。心电图(electrocardiogram, ECG)能提供心脏活动的信息,对各种心律失常的分析诊断具有极为重要的意义^[1]。而心律失常存在偶发性,临床上需要对患者进行全时段的连续监控。对于如此庞大的心电图数据,传统人工诊断的方法需要较高水平的专家事先深入了解心房颤动特征,也需要心内科医生费时费力地解读电信号。为避免耽误患者的最佳治疗时机,自动、准确的心电图分类技术一直是研究重点之一。

当前,心电图分类算法主要分为两种:基于手动提取特征的方法和基于端到端深度学习的方法。手动提取特征依赖于人工提取特征的质量,质量越高则后续心电图分类效果越好。2005年,ZHAO等^[2]运用小波变换提取变换系数,并将其作为每个心跳信号的特征,利用高斯核支持向量机对不同的心跳信号进行分类;2020年,LIU等^[3]提出利用小波散射变换自动分辨4类心律失常心跳信号,在8个时间窗口上应用了主成分分析和时间窗口选择这两种降维方法来提取用于分类的特征;2020年,YANG等^[4]提出了将qrs波(又称“心室除极波”,ventricle depolarization wave)的复杂形态变化作为特征并使用基于聚类的特征分类算法;2021年,ZHANG等^[5]提出了多导联分支融合网络架构,并将其与集成多损失优化联合来学习多导联心电图的多样性和完整性。然而,人工特征提取方法分类准确度依赖于手动提取的特征,而手

动提取的特征的质量也可能良莠不齐。此外,分类准确度也受制于后续分类器的影响,可能无法捕捉到更深层次的特征。

自端到端的深度学习兴起以来,国内外各学者将各种算法应用于心电图信号的心律失常检测和分类中。2018年,MOUSAVI等^[6]将深度卷积神经网络和序列到序列模型用于自动心跳分类方法,取得了94.3%的分类准确率;2018年,GOODFELLOW等^[7]使用卷积神经网络分类器模型,并采取注意力机制提取类别和激活映射对心电图信号进行分类,取得了92.1%的分类准确率;2020年,ROHMANTRI等^[8]将每个心跳信号绘制成单独的二维灰度图像,并将图像在二维卷积神经网络中进行心跳分类,取得了97.8%的准确率。

基于深度学习的心电图分类算法已经取得了不错的成绩。但是,目前大部分算法都是对时域信号进行分类,分类难度更高,且耗时更长。受HUANG等^[9]的启发,本研究先将时域信号转化为频域信号再进行分类,从而在节省分类时间的基础上提高分类准确度。然而,传统的短时傅里叶变换窗函数是固定的,一旦被确定,其形状就不再发生改变,其分辨率也无法改变^[10]。

小波变换(wavelet transform, WT)^[11]继承和发展了短时傅里叶变换的思想,但与短时傅里叶变换不同的是,小波变换的基函数是有限长、会衰减的小波基,可以实现正交化,并且其尺度可以变化。小波变换能够在低频时提供高频分辨率和低频分辨率,还可以在高频时提供高时间分辨率和低频分辨率^[12]。

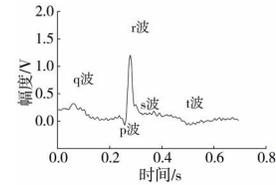
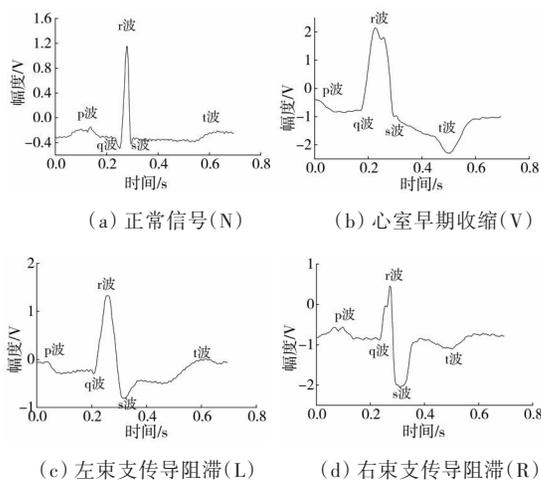
因此,本研究使用基于连续小波变换(continuous wavelet transform, CWT)和Inception的心电图自动分类方法——CWT-Inception,采用连

续小波变换对数据进行优化增强,以 Inception 网络作为特征提取网络和分类器进行了试验。试验结果表明,对于阳性预测值和召回率等指标而言, Inception 网络作为并行结构网络能将不同宽度的特征矩阵按深度进行拼接,比残差网络(residual network, ResNET)、视觉几何群(visual geometry group, VGG)网络等常见网络能提取到更丰富的特征。此外,相对于其他小波函数,本研究采用的墨西哥小波(Mexh)能更好地表征单个心跳形状,其分类效果最好。

1 数据及预处理

1.1 ECG数据集

本文采用美国麻省理工学院(Massachusetts Institute of Technology, MIT)和波士顿以色列医院(Boston's Beth Israel Hospital, BIH)联合建立的研究心律失常的数据库(下文均以 MIT-BIH 代替)。此数据库包含以 360 Hz 采样的 47 个 ECG, 每个 ECG 约 30 min。这些心电信号以三位数编号(如 100、101)存储,且每组编号数据都包含两路不同导联方式的 ECG^[13-14]。由于 MIT-BIH 数据库中有详细的位置标注和类型标注,本文从中选取了 5 种心跳类型,即正常信号心跳(normal beat, N)、心室早期收缩(ventricular premature contraction, V)、左束支传导阻滞(left bundle branch block, L)、右束支传导阻滞(right bundle branch block, R)和心房过早收缩(atrial premature contraction, A)。图 1 是这 5 种心跳信号的时域图。



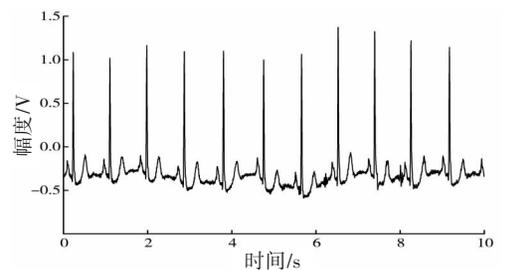
(e) 心房过早收缩(A)

图 1 5种心跳的时域图

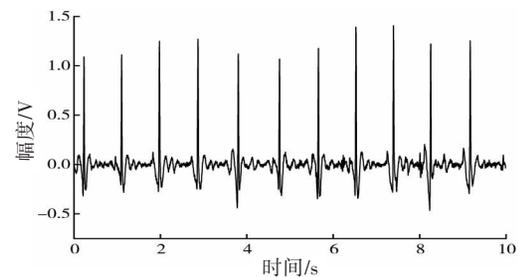
Fig. 1 Time-domain graph of five types of heartbeats

1.2 信号预处理

临床采集的 ECG 信号通常会受到各种噪声的干扰,如肌电图干扰和电源线干扰等,产生信号基线漂移等现象。这使得从原始 ECG 信号中提取有用信息变得困难^[15]。因此,研究者在进一步处理之前必须对噪声进行滤波处理。但过多的滤波处理会导致有用信息可能丢失,故本研究仅去除噪声基线漂移。本研究在预处理阶段使用 4 阶多贝西(daubechies 4, Db4)小波变换对心电信号的基线漂移进行去噪处理。图 2 展示了 10 s 时长的原始的和去噪的 ECG 信号,其中的信号采样频率为 360 Hz,采样点数为 3 600。从图 2 可以看出去噪后的信号是在一条基准线上波动的。这对之后的心电图分割提供了便利并提高了准确率。



(a) 原始信号



(b) 去基线漂移后的信号

图 2 原始信号和去基线漂移后的信号对比

Fig. 2 Comparison of original signal and signal after debaseline drift

本研究在对心电图信号进行分类之前,需要从心电图信号中分割出单个的心跳。图 3 是心电图信号分割示意图。以图 3 为例,本研究以 MIT-BIH

数据库中的 r_i 波的波峰为中心,将单个 ECG 波峰信号分割成 250 个采样点,且每个采样点都是 0.694 s 的心跳片段。本研究截取图 3 中 3.3~6.3 s 时段包含的三个心跳信号。具体来说,以 r_i 波为例,本研究从自 r_i 波波峰所在时刻向前 0.278 s 的时段获得 100 个采样点,同时从自 r_i 波波峰所在时刻向后 0.416 s 的时段获得 150 个采样点,即可组成完整的 r_i 波心跳信号。对 r_{i-1} 波、 r_{i+1} 波的信号分割处理类似进行。

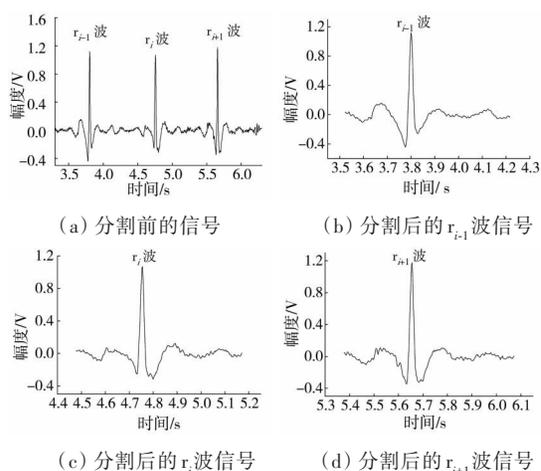


图 3 心电信号分割

Fig. 3 ECG signal segmentation

表 1 列出了 46 组 30 min 时长的数据集在分割之后包含的 N、V、L、R、和 A 类心跳信号的数量。

表 1 分割后的 L、R、V、N 和 A 类心跳信号的数量统计

Table 1 Statistical results of L, R, V, N, and A heartbeat signals after segmentation

类型	数量	类型	数量
N	74 962	V	7 034
L	8 068	R	7 254
A	2 545	共计	

2 小波变换获取时频图

由于心跳信号由不同的频率分量组成,因此本研究将心跳信号转换为时频图,以便于使用 Inception 进行特征提取和分类^[16]。作为最常用的时频分析工具之一,CWT 使用一系列小波基函数对时域信号进行分解,已经被应用于各种大数据驱动等场合^[17]。

对于给定某时刻 t 的信号 $x(t)$,CWT 被定义为

$$C_a = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \cdot \varphi\left(\frac{t-b}{a}\right) dt \quad (1)$$

$$F = \frac{F_c \cdot f_s}{a} \quad (2)$$

式(1)~(2)中: a 是尺度参数; b 是平移参数; C_a 是对信号 $x(t)$ 进行 CWT 变换得到的参数; $\varphi(t)$ 是小波基函数(又称母小波); F 是信号的频率; F_c 是母小波的中心频率; f_s 是信号 $x(t)$ 的采样频率。

母小波是影响时频分析效果的关键因素。墨西哥小波(mexican wavelet, Mexh)基函数因为其形状接近 QRS 波的形状,故在本研究中被采用并作为母小波。墨西哥小波基函数表达式如下:

$$\varphi(t) = \frac{2}{\sqrt{3} \sqrt[4]{\pi}} \exp\left(-\frac{t^2}{2}\right) (1-t^2)x(t) \quad (3)$$

本研究通过调节 a 和 b 的大小来获得信号在不同尺度下的小波系数。这些小波系数是心跳信号时频域的二维尺度图,也称时频图。5 种心跳的时频图如图 4 所示。

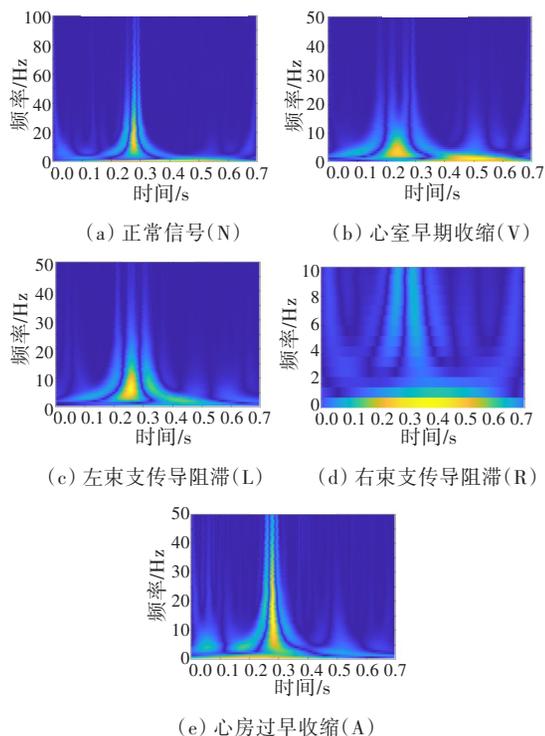


图 4 五种心跳的时频图

Fig. 4 Time-frequency graphs of five types of heartbeats

在图 4 中,正常信号的 r 波像尖峰一样变化剧烈(在图 1 中为 0.25 s 左右),左束支传导阻滞和心室早期收缩的 r 波尖峰变化缓慢;正常信号 t 波与 r 波方向一致,心室早期收缩和右束支传导阻滞的 t 波与 r 波方向相反,而心房过早收缩的 p 波提前出

现,并且 p-r 间期大于 0.12 s。在一些情况下,5 种心跳在时域图上并无明显差别,可能会被错检或漏检。但是,心跳信号在被转换为时频图后,则可从时间和频率两方面被区分出来。正常信号时频图在 0.30 s、10~30 Hz 时出现明显黄线尖峰,这表明正常心跳小波系数在 0.30 s、10~30 Hz 时最大。同理,左束支传导阻滞心跳小波系数在 0.25 s、0~10 Hz 时最大,心室早期收缩心跳小波系数分别在 0.20~0.30 s、5~8 Hz 和 0.40~0.60 s、1~3 Hz 时最大,右束支传导阻滞小波系数在 0.20~0.50 s、1~2 Hz 时最大,心房过早收缩小波系数在 0.21~0.25 s、2~10 Hz 时最大。这些都表明时频图是可以用于心跳信号分类的。然而,由于时频图 and 不同信号之间的关系难以明确,故业界大多使用基于预训练的 Inception 网络对 5 种时频图进行分类。

3 模型搭建

卷积神经网络(convolutional neural network, CNN)常被用于图像分类技术^[18]。本文的 Inception 网络是典型的 CNN。Inception 网络的主体部分 Inception 层如图 5 所示。

从图 5 可以看出,Inception 层包括 4 个 1×1 卷积核、1 个 3×3 卷积核、1 个 5×5 卷积核和 1 个 3×3 最大池化层。Inception 网络通过这些卷积核和池化层能够得到不同尺度的特征矩阵。

在 Inception 网络中,多个卷积核同时处理特

征矩阵的数据,随后按深度进行拼接,得到最终输出数据。采用的 1×1 卷积核能够让 4 个分支所得特征数据矩阵的高度和宽度均相同,以便拼接能够在深度方向上进行;Inception 层结构能够用于降维处理,能大幅度减少参数数量。由于在试验中加入了预训练的方法,Inception 网络拥有了识别底层通用特征的能力,能更快学习新数据集中的高维特征,其学习和处理过程比不使用迁移学习的方法更快且更准确^[19]。

本研究首先将原 Inception 的模型参数迁移到搭建的心电图分类模型,然后调整网络结构,以提取心跳信号时频图特征并进行识别和分类。Inception 网络的预训练学习过程如图 6 所示。

Inception 网络包括 9 个初始层模块和 2 个 Softmax 层。ImageNet 数据集经过 3 个卷积层(其中一层大小为 7、步长为 2;另两层大小均为 3、步长均为 1)、2 个最大池化层(大小均为 3、步长均为 2);接着,被送入 9 层 Inception 层模块中(其中在

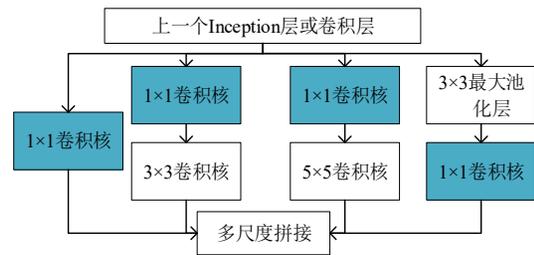


图 5 Inception 层结构

Fig. 5 Inception layer structure

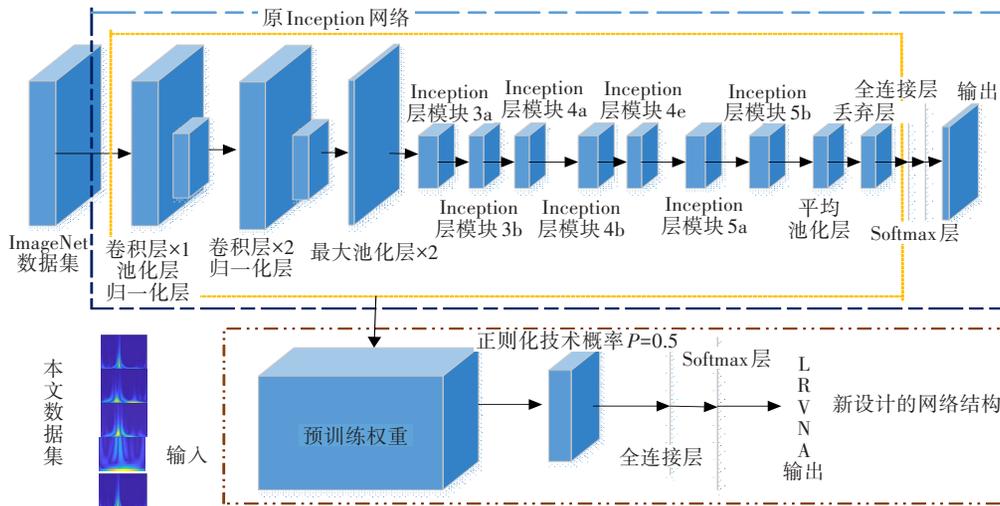


图 6 预训练学习过程

Fig. 6 Pre-training learning process

Inception层3b、4a、4e、5a模块中都含有一个最大池化层);然后,被依次送入平均池化层、丢弃层、全连接层和Softmax层;最后,被送入分类层。

为适应心电图信号的时频图像,本研究微调原Inception模型架构,将原网络中包含1 000个节点的全连接层替换为包含5个节点的全连接层,而其他参数保持不变。此外,本研究在Inception中载入了Inception网络的预训练权重,将网络模型参数进行迁移,从而确保预训练网络能够获得丰富的各种底层特征和中高层特征。为了防止过拟合,正则化技术概率 P 值被设定为0.5。

图6中的Softmax层被用于对心跳信号时频图归属心跳类型的概率进行计算,并将概率值最大的类型作为预测输出,进而通过比较预测输出与期望输出的差值来更新各层参数。同时,本研究联合反向传播算法和最小化交叉熵损失(cross entropy loss, CEL)函数来更新参数。CEL函数值 L_{loss} 可以按照式(4)进行计算。

$$L_{\text{loss}} = - \sum_{i=1}^{N_T} \sum_{j=1}^K t_{ij} \ln y_{ij} \quad (4)$$

式中: N_T 为类别样本数; K 为类别数; t_{ij} 为第 i 个样本属于类别 j 的概率; y_{ij} 为输出概率。

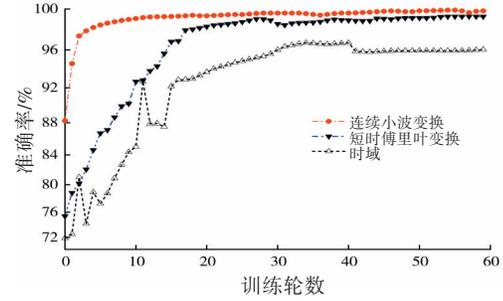
4 试验仿真

本文使用MATLAB 2019b和CWT对心电图进行分割,并在Nvidia GTX 1080 GPU上训练该Inception模型。该模型训练的初始超参数权重使用对应训练集的训练权重值。本研究将数据集按照9:1划分为训练集和测试集,其中小批量(mini-batch)大小为32。本研究有60轮训练,每轮迭代2 737次,共迭代164 220次。训练中,本文网络模型被设定为在每一轮训练之后都进行一次验证。

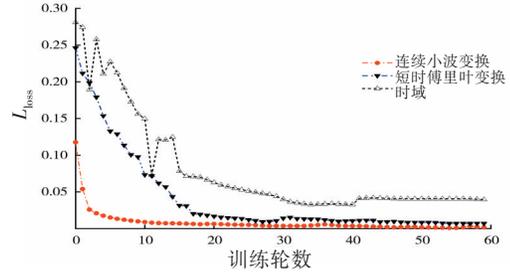
4.1 试验过程

图7展示了分别单独采用时域信号特征、短时傅里叶变换所得特征及连续小波变换所得特征作为输入特征时的准确率曲线和损失函数值曲线。

从图7可以看到:以连续小波变换和使用短时傅里叶变换所得的频谱信号作为输入时,网络收敛更快,更快达到稳定;采用时频信号的准确率比采用时域信号的更高;采用连续小波变换的网络



(a) 三种输入的准确率曲线图



(b) 三种输入的损失函数值曲线图

图7 三种输入的准确率和损失函数值曲线

Fig. 7 Accuracy and loss function value curves for three inputs

比采用短时傅里叶变换的网络收敛更快,准确率更高,降低了后续分类的难度,加速了网络训练。

4.2 分类表现

在二分类任务中, H_p 、 J_p 、 K_n 、 I_n 分别为正类样本被正确预测为正类的数量、正类样本被错误预测为负类的数量、负类样本被正确预测为负类的数量、负类样本被错误预测为正类样本的数量。在本文的多分类任务中,正类样本和负类样本是相对的: N 被预测为 N 类样本属于正类样本被预测正确; N 类样本被预测为其他4类属于正类样本被预测错误。

为了评价该方法的性能,本研究采用了三个广泛使用的指标^[20],即阳性预测值、召回率和准确率,其数值分别用 P_a 、 R_c 、 A_c 表示。

$$P_a = \frac{H_p}{H_p + I_n} \times 100\% \quad (5)$$

$$R_c = \frac{H_p}{H_p + J_p} \times 100\% \quad (6)$$

$$A_c = \frac{H_p + K_n}{H_p + I_n + J_p + K_n} \times 100\% \quad (7)$$

在4.1节训练完Inception网络并保存好最佳权重,即在得到第55轮训练的权重之后,本研究将测试数据送入网络进行评估,得到测试集混淆矩阵,如图8所示。在图8中,横坐标为心跳的真实

标签,纵坐标为模型判定的预测标签,主对角线的数值为模型预测正确的频次,对角线以外的数值为预测错误的频次。从图8可以看出,(L,R)的值为1,即模型在测试集上将L类样本预测为R类样本的频次为1。从图8还可以看出,网络对N、L、R和A类的心跳信号的识别效果很好:对于真实输出为N类的心跳信号,网络能够完全识别出来;对于真实输出为L类的心跳信号,偶有几张心跳信号会被网络识别成N类,但更多的信号被成功识别;对于真实输出为R类和A类的心跳信号,网络的识别错误率也非常小。

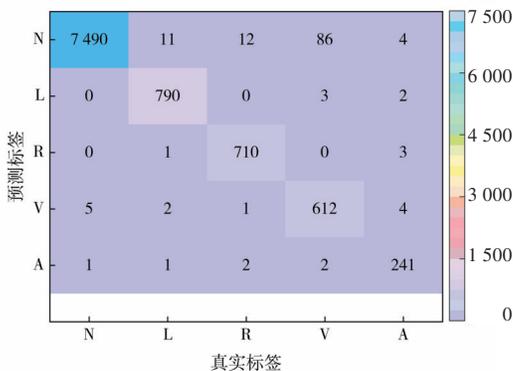


图8 测试集混淆矩阵

Fig. 8 Test set confusion matrix

本文网络模型的整体性能如表2所示。从表2可以看出,对于正常类(即N类)心跳信号,本文网络模型的阳性预测值达到99.5%以上,召回率达到100%,准确率达到98.1%。这说明CWT-Inception模型能够媲美人工分类,并且速度更快。

表2 CWT-Inception模型整体性能

Table 2 Overall performance of CWT-Inception model %

类型	阳性预测值	召回率	准确率
N	99.5	100.0	98.1
L	98.6	95.1	99.9
R	99.9	100.0	98.2
V	98.4	99.9	87.2
A	99.8	99.9	99.1

此外,表3列出了不同的神经网络分类模型在同一数据集上的分类性能。从表3可以看出,本文的CWT-Inception模型在阳性预测值和准确率两个指标上的表现优于其他模型的,但在召回率上的表现排名第二。相对于仅提取时域信息的网络模型^[21],本文中的网络模型在分类准确率方面要高出4.4个百分点,具有明显的优越性。

表2、表3均表明,本文的CWT-Inception模型

能够充分利用心电信号的时域信息,不仅学习了5种类别的外在特征,也学习了丰富的频域信息和其他潜在特征。此外,相比于传统的分类器,端到端的Inception网络不仅能够对输入信号特征的多个分支进行处理,对不同宽度的特征矩阵按深度进行拼接,还能直接进行分类而不需要手动调整网络架构。

表3 本文与其他分类模型的试验结果

Table 3 Experimental results of proposed model and other classification models %

模型	阳性预测值	召回率	准确率
1D-GoogLeNet ^[21]	96.6	95.7	94.4
ResNet-31 ^[22]	99.0	93.2	96.8
LSTM+CNN ^[23]	98.1	97.5	98.7
本文模型	99.1	95.9	98.8

5 讨论

5.1 小波类型的选择

CWT是时频域中最常用的信号分析工具,但业界在小波函数的选择上没有统一的标准。本文除了使用了Mexh,还使用了其他三种广泛使用的小波函数,即高斯小波(Gaus8)、Db4小波和迈耶小波(Meyer)。他们的整体性能如表4所示。

从表4可以看出:墨西哥小波的阳性预测值在所述四种小波中效果最好,达到了99.1%,比Meyer小波的高0.9个百分点;墨西哥小波的准确率最大,达到了98.7%;墨西哥小波的召回率仅比最大的Db4小波的小0.1个百分点,位列第二。这说明墨西哥小波在形状上与心跳信号形状更相似。因此,本文采用的墨西哥小波具有良好的整体综合性能,有利于后续网络的训练与学习,对提高网络识别率有很好的效果。

小波函数图像如图9所示。在这些小波函数中,墨西哥小波的波形最接近心跳信号的波形,其

表4 使用不同小波基得到的模型整体性能

Table 4 Overall performance of different models obtained by different wavelet bases %

母小波	阳性预测值	召回率	准确率
墨西哥小波(Mexh)	99.1	98.8	98.7
高斯小波(Gaus8)	98.4	97.9	95.1
多贝西小波(Db4)	98.9	98.9	98.2
迈耶小波(Meyer)	98.2	87.2	97.9

次是 Db4 小波的,而 Gaus8 小波和 Meyer 小波的波形与 ECG 信号的不同。故心跳信号的波形与小波函数的波形相似度越高,小波函数的性能越好。业界在信号分析时应尽量选择使用最接近待分析信号波形的小波基函数。

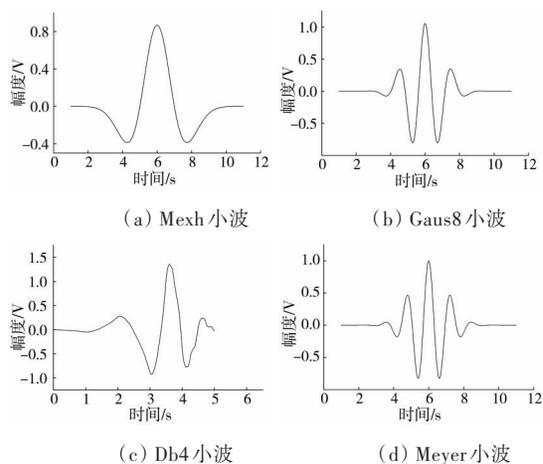
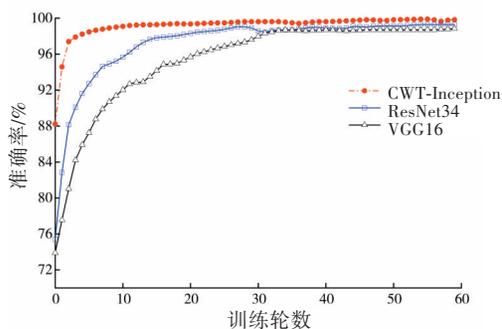


图 9 小波函数图像

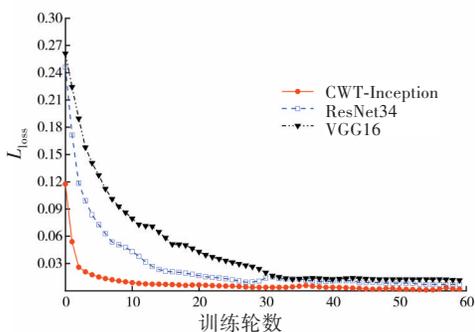
Fig. 9 Wavelet function image

5.2 网络模型选取

在训练参数相同的条件下,本将 CWT-Inception 和其他著名的 VGG16、ResNet34 网络框架进行对比。相关结果如图 10 所示。



(a) 三种模型训练曲线的准确率



(b) 三种模型训练曲线的损失函数

图 10 三种模型训练曲线的准确率与损失函数值

Fig. 10 Accuracy and loss function value of three model training curves

从图 10 可以看出:随着迭代次数增加,各模型的训练准确率均超过 96.3%;CWT-Inception 是收敛最快的模型,其准确率在第 3 轮训练时已经大于 96.4%;其他两个模型在第 30 轮训练时才趋于收敛。

5.3 优化算法对模型性能的影响

在机器学习算法中^[24-25],最常用的优化算法有适应性梯度算法(adaptive moment estimation, Adma)、随机梯度下降算法(stochastic gradient descent momentum,SGDM)和均方根传播优化算法(root mean square propagation,RMSprop)。本文分别从训练时长、验证准确率和测试准确率三方面对这三种优化算法进行比较,其结果如图 5 所示。从表 5 可以看出:SGDM 算法的验证准确率比 Adam 算法的大 0.1 个百分点,SGDM 算法的测试准确率方面也比 Adam 算法的大 0.5 个百分点,SGDM 算法的训练时长比 Adam 算法的要少 1.3 h。总体来看,SGDM 算法更适于本研究。

表 5 三种优化算法比较

Table 5 Comparison of three optimization algorithms

优化算法	训练时长/h	验证准确率/%	测试准确率/%
Adam	6.1	95.7	91.3
SGDM	4.8	95.8	91.8
RMSprop	5.9	85.7	77.9

6 结论

本文基于 CWT 和 Inception,提出了一种新的心电图分类方法——CWT-Inception。本研究首先使用 CWT 将 ECG 心跳信号从时域转换到时频域,然后利用 Inception 网络从分解后的小波系数组成的时频图中提取特征并进行自动分类,最后在训练中采用 SGDM 算法进行模型优化。

本文主要结论如下:

1) 连续小波变换将一维心跳信号转换为二维时频数据,提取了包括时域和时频域在内的多维特征。试验结果表明,采用小波基的准确率比采用时域或短时傅里叶变换的更高,且小波基函数收敛更快。

2) 本研究选取 4 种常见小波基函数,即墨西哥小波、Db4 小波、Gaus8 小波和 Meyer 小波,并进行比较。结果表明,墨西哥小波与心跳形状更接

近,其阳性预测值和召回率均为最大。

3) 本研究使用端到端的 Inception 网络来进行特征提取和分类,并在心律失常数据库 MIT-BIH 上进行测试。研究表明,CWT-Inception 网络模型在阳性预测值、召回率和准确率等指标上表现很好,充分显示出端到端的网络模型的优越性,并且能直接进行特征提取和分类而不需手动调整。与其他预训练模型,如 VGG16 和 ResNet34 模型相比,CWT-Inception 模型收敛最快,其准确率达到 99.1% 以上。这说明 CWT-Inception 网络能够对不同维度的特征矩阵进行拼接,能更好地提取潜在特征。

4) 在几种优化算法中,SGDM 算法更适于心跳信号分类研究,且耗时最短、准确率最大。

[参考文献]

- [1] 樊承柱. 基于深度神经网络的心电图自动分类方法研究与实现[D]. 济南: 山东大学, 2016.
FAN Chengzhu. Research and Practice on Deep Neural Network Based ECG Automatic Classification[D]. Ji'nan: Shandong University, 2016.
- [2] ZHAO Qibin, ZHANG Liqing. ECG feature extraction and classification using wavelet transform and support vector machines[C]//Proceedings of 2005 International Conference on Neural Networks and Brain. Beijing: China, IEEE, 2005: 1089-1092. DOI: 10.1109/ICNNB.2005.1614807.
- [3] LIU Zhishuai, YAO Guihua, ZHANG Qing, et al. Wavelet scattering transform for ECG beat classification [J]. Computational and Mathematical Methods in Medicine, 2020 (7) : 1-11. DOI: 10.1155/2020/3215681.
- [4] YANG H, WEI Z Q. Arrhythmia recognition and classification using combined parametric and visual pattern features of ECG morphology[J]. IEEE Access, 2020, 8: 47103-47117. DOI: 10.1109/ACCESS.2020.2979256.
- [5] ZHANG Jing, LIANG Deng, LIU Aiping, et al. MLBF-Net: a multi-lead-branch fusion network for multi-class arrhythmia classification using 12-lead ECG [J]. IEEE Journal of Translational Engineering in Health and Medicine, 2021, 9: 1900211. DOI: 10.1109/JTEHM.2021.3064675.
- [6] MOUSAVI S, AFGHAH F. Inter- and intra-patient ECG heartbeat classification for arrhythmia detection: a sequence to sequence deep learning approach [C]// Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Brighton, UK: IEEE, 2019: 1308-1312. DOI: 10.1109/ICASSP.2019.8683140.
- [7] GOODFELLOW S D, GOODWIN A, GREER R, et al. Towards understanding ECG rhythm classification using convolutional neural networks and attention mappings [J]. Machine Learning for Healthcare, 2018, 85: 1-18.
- [8] ROHMANTRI R, SURANTHA N. Arrhythmia classification using 2D convolutional neural network [J]. International Journal of Advanced Computer Science and Applications, 2020, 11 (4) : 201-208. DOI: 10.14569/ijacsa.2020.0110427.
- [9] HUANG Jingshan, CHEN Binqiang, YAO Bin, et al. ECG arrhythmia classification using STFT-based spectrogram and convolutional neural network [J]. IEEE Access, 2019, 7: 92871-92880. DOI: 10.1109/ACCESS.2019.2928017.
- [10] PORTNOFF M. Time-frequency representation of digital signals and systems based on short-time Fourier analysis [J]. IEEE Transactions on Acoustics, Speech, and Signal Processing, 1980, 28(1) : 55-69. DOI: 10.1109/TASSP.1980.1163359.
- [11] DAUBECHIES I. The wavelet transform, time-frequency localization and signal analysis [J]. IEEE Transactions on Information Theory, 1990, 36 (5) : 961-1005. DOI: 10.1109/18.57199.
- [12] GUO Moufa, ZENG Xiaodan, CHEN Duanyu, et al. Deep-learning-based earth fault detection using continuous wavelet transform and convolutional neural network in resonant grounding distribution systems [J]. IEEE Sensors Journal, 2018, 18 (3) : 1291-1300. DOI: 10.1109/JSEN.2017.2776238.
- [13] TALO M, BALOGLU U B, YILDIRIM Ö, et al. Application of deep transfer learning for automated brain abnormality classification using MR images [J]. Cognitive Systems Research, 2019, 54: 176-188. DOI: 10.1016/j.cogsys.2018.12.007.
- [14] MOODY G B, MARK R G. The impact of the MIT-BIH arrhythmia database [J]. IEEE Engineering in Medicine and Biology. 2001, 20 (3) : 45-50. DOI: 10.1109/51.932724.
- [15] 孔飞. 基于小波变换和神经网络的心电图分类识别研究[D]. 成都: 电子科技大学, 2015. DOI: 10.7666/d.D664318.
KONG Fei. The study of ecg classification and recognition based on wavelet transform and neural network [D]. Chengdu: University of Electronic Science and Technology of China, 2015. DOI: 10.7666/d.D664318.
- [16] WANG Tao, LU Changhua, SUN Yining, et al. Automatic ECG classification using continuous wavelet transform and convolutional neural network [J].

- Entropy, 2021, 23 (1) : 119. DOI: 10.3390/e23010119.
- [17] 杨明, 周斯维, 谷健. 基于数据驱动的城市居民出行OD预测[J]. 长沙理工大学学报(自然科学版), 2022, 19(1) : 73-80. DOI: 10.19951/j.cnki.1672-9331.2022.01.009.
- YANG Ming, ZHOU Siwei, GU Jian. Traffic OD prediction of urban residents based on data driven[J]. Journal of Changsha University of Science & Technology (Natural Science), 2022, 19(1) : 73-80. DOI: 10.19951/j.cnki.1672-9331.2022.01.009.
- [18] 龚红仿, 孙中宇, 狄俊珂. 基于滑动平均与规则决策的卷积神经网络图像分类[J]. 长沙理工大学学报(自然科学版), 2020, 17(3) : 102-110. DOI: 10.3969/j.issn.1672-9331.2020.03.014.
- GONG Hongfang, SUN Zhongyu, DI Junke. Convolutional neural network for image classification based on moving average and rule decision[J]. Journal of Changsha University of Science & Technology (Natural Science), 2020, 17(3) : 102-110. DOI: 10.3969/j.issn.1672-9331.2020.03.014.
- [19] 庄福振, 罗平, 何清, 等. 迁移学习研究进展[J]. 软件学报, 2015, 26(1) : 26-39. DOI: 10.13328/j.cnki.jos.004631.
- ZHUANG Fuzhen, LUO Ping, HE Qing, et al. Survey on transfer learning research[J]. Journal of Software, 2015, 26(1) : 26-39. DOI: 10.13328/j.cnki.jos.004631.
- [20] 林南亭, 胡林, 林淼, 等. 基于时间序列聚类的交通事故黑点识别与分析[J]. 长沙理工大学学报(自然科学版), 2023, 20(2) : 45-54. DOI: 10.19951/j.cnki.1672-9331.20230101002.
- LIN Nanting, HU Lin, LIN Miao, et al. Black spot identification and analysis of traffic accidents based on time series clustering [J]. Journal of Changsha University of Science & Technology (Natural Science), 2023, 20(2) : 45-54. DOI: 10.19951/j.cnki.1672-9331.20230101002.
- [21] 杨淑莹, 桂彬彬, 陈胜勇. 基于小波分解和1D-GoogLeNet的心律失常检测[J]. 电子与信息学报, 2021, 43(10) : 3018-3027. DOI: 10.11999/JEIT200774.
- YANG Shuying, GUI Binbin, CHEN Shengyong. Arrhythmia detection based on wavelet decomposition and 1D-GoogLeNet [J]. Journal of Electronics and Information Technology, 2021, 43(10) : 3018-3027. DOI: 10.11999/JEIT200774.
- [22] LI Zhi, ZHOU Dengshi, WAN Li, et al. Heartbeat classification using deep residual convolutional neural network from 2-lead electrocardiogram [J]. Journal of Electrocardiology, 2020, 58: 105-112. DOI: 10.1016/j.jelectrocard.2019.11.046.
- [23] OH S L, NG E Y K, TAN R S, et al. Automated diagnosis of arrhythmia using combination of CNN and LSTM techniques with variable length heart beats [J]. Computers in Biology and Medicine, 2018, 102: 278-287. DOI: 10.1016/j.combiomed.2018.06.002.
- [24] 朱文静, 张映雪, 武焱, 等. 优化MGM(1, n)模型在边坡沉降预测中的应用研究[J]. 交通科学与工程, 2023, 39(2) : 105-113. DOI: 10.16544/j.cnki.cn43-1494/u.20211023001.
- ZHU Wenjing, ZHANG Yingxue, WU Yan, et al. Application of optimized MGM (1, n) model in slope settlement prediction [J]. Journal of Transport Science and Engineering, 2023, 39(2) : 105-113. DOI: 10.16544/j.cnki.cn43-1494/u.20211023001.
- [25] 王佳, 郑天玉, 王祎, 等. 基于模糊贝叶斯网络的危险货物道路运输风险评价[J]. 公路与汽运, 2023(6) : 52-58. DOI: 10.20035/j.issn.1671-2668.2023.06.011.
- WANG Jia, ZHENG Tianyu, WANG Yi, et al. Risk assessment of road transport of dangerous goods based on fuzzy Bayesian network [J]. Highways & Automotive Applications, 2023(6) : 52-58. DOI: 10.20035/j.issn.1671-2668.2023.06.011.

(责任编辑:彭三军;校对:毛娜)