

基于连续小波变换和高阶统计量的心律失常识别算法

李刚¹, 高广帅¹, 张珍珍², 巴任伟¹, 李春雷¹, 刘洲峰¹

1. 中原工学院电子信息学院, 河南 郑州 450007; 2. 郑州人民医院郑东院区门诊部, 河南 郑州 450014

【摘要】针对可变速率心电图(ECG)数据信号的非平稳性和时序性问题,提出一种基于连续小波变换(CWT)和高阶统计量(HOS)的心律失常识别算法。首先,针对可变速率ECG数据中每个样本的数据点数量不同,采用RR间期插值法预处理数据,并通过CWT将信号分解为不同的时频分量,从而使网络能够更好地提取心电信号中的时间和频率特征。其次,针对时序信息利用不充分的问题,提出基于HOS和长短期记忆网络的时序挖掘模块,以捕捉和学习ECG信号中的长期依赖关系,从而有助于识别和理解特定的心律失常类别。通过在公开的ECG数据集MIT-BIN上进行的大量实验,验证所提方法的有效性和优越性。

【关键词】心律失常识别;连续小波变换;高阶统计量;长短期记忆网络;RR间隔

【中图分类号】R318;TP319

【文献标志码】A

【文章编号】1005-202X(2024)03-0365-10

Arrhythmia identification algorithm based on continuous wavelet transform and higher-order statistics

LI Gang¹, GAO Guangshuai¹, ZHANG Zhenzhen², BA Renwei¹, LI Chunlei¹, LIU Zhoufeng¹

1. School of Electronic and Information, Zhongyuan University of Technology, Zhengzhou 450007, China; 2. Outpatient Department, East District Branch of People's Hospital of Zhengzhou, Zhengzhou 450014, China

Abstract: Aiming at the non-stationarity and temporal characteristics of variable-length electrocardiogram (ECG) signals, an arrhythmia identification algorithm is proposed based on continuous wavelet transform and higher-order statistics. Considering the varying number of data points for each sample in variable-length ECG signals, the RR interval interpolation method is employed for data preprocessing, and the signal is decomposed into different time-frequency components using continuous wavelet transform, which enables the network to better extract both temporal and frequency features from the ECG signals. Regarding the issue of insufficient utilization of temporal information, a temporal mining module is introduced based on higher-order statistics and long short-term memory network to capture and learn long-term dependencies in the ECG signals, thereby facilitating the identification and understanding of specific arrhythmia categories. Extensive experiments conducted on the publicly available MIT-BIH ECG database validate the effectiveness and superiority of the proposed method.

Keywords: arrhythmia identification; continuous wavelet transform; higher-order statistics; long short-term memory; RR interval

前言

心律失常是临床上最常见的心血管疾病之一,严重时甚至会危及生命,例如心房颤动会导致中风

和心脏骤停等。在临床上,心律失常的识别通常通过医生分析心电图(ECG)信号的心跳来诊断,尽管简单有效,但耗时且费力。自动ECG信号识别方法可以有效帮助医生诊断病情,提升工作效率。因此,心律失常自动识别方法逐步成为研究热点。传统识别方法如决策树^[1-3]、支持向量机^[4-5]、基于多视图的学习^[6-7]和线性判别^[8-10]等,取得了一定的分类性能。但是,不同患者的ECG波形及其形态特征存在显著差异。即使对于同一患者,不同时间的ECG波形也有所不同,导致这些方法的分类精度不高,自适应能力较差。

【收稿日期】2023-09-18

【基金项目】国家自然科学基金(62072489)

【作者简介】李刚,硕士,研究方向:基于深度学习的心电图信号处理与分类, E-mail: 1533585475@qq.com

【通信作者】李春雷,博士,教授,研究生导师,研究方向:计算机视觉及人工智能、图像处理与模式识别, E-mail: lichunlei1979@zut.edu.cn

近年来,深度学习在医学信号处理中表现优异,尤其是卷积神经网络(Convolutional Neural Network, CNN)和循环神经网络(Recurrent Neural Network, RNN)在ECG分类中得到成功应用。通过对大量数据进行学习,可提取更抽象和更丰富的特征信息,显著提升检测、识别分类等任务的性能。例如Yildirim等^[11]在MIT-BIH心律失常数据库^[12]上提出一种用于心律失常分类的一维CNN分类模型,该模型是分类精度较高的16层深度卷积网络。Wang等^[1]利用连续小波变换(CWT)将一维心电变换为二维时频心电频谱图像,然后将得到的心电频谱图像输入到二维CNN中,该方法将一维信号转换为二维信号,使CNN的特性得到充分利用。Acharya等^[13]使用基于CNN方法,通过使用数据增强技术和训练数据平衡方法,在准确率和鲁棒性方面表现出色。Hou等^[14]提出一种新的深度学习网络,该网络基于长短期记忆自编码器网络提取心律失常数据的特征,并使用支持向量机从学习到的特征中对心律失常进行分类。Jyotishi等^[15]使用基于长短期记忆网络(Long Short-Term Memory, LSTM)的方法,具有较强的抗噪声和时序特征提取能力,在不需要手动特征标注的情况下能够达到很高的准确率。Chen等^[16]提出一种新的心电分类网络,该网络由5个卷积神经网络块、1个具有注意机制的双向门递归单元和1个全连接分类器组成,并取得很好的分类效果。Wang等^[17]提出的方法由33层CNN架构和非局部卷积块关注模块组成,该方法中的CNN架构旨在提取ECG的空间和通道特征,非局部注意捕获沿空间和通道轴的代表性特征的长依赖关系。Strodthoff等^[18]使用时间序列分类中一些最先进的网络进行心电分类,包括全卷积网络、一维残差网络、InceptionTime等网络,这些网络在心电分类方面也表现良好。

但是,以上方法大多是从时序特征或者空间特征单方面去挖掘数据特征,存在对数据信息利用不够充分的问题。因此,本文提出一种基于CWT和高阶统计量(Higher-Order Statistics, HOS)的心律失常识别算法。针对可变持续时间ECG数据的问题,通过RR间期插值法,使处理后的原始数据转化为等长的信号序列。针对心电信号具有较高的时频分辨率的问题,通过CWT可以将心电信号分解为不同的时频分量,使得卷积神经网络更好地提取心电信号中的时间和频率特征^[19]。为了利用心电信号中的时序信息,引入RNN中的LSTM模型,有效捕捉心电信号中的长时依赖关系,同时使用加权交叉熵损失函数,缓解数据分布不均衡的问题。最后,将以上两种模型提取的特征进行融合,从而提升对心电信号的识

别能力。通过在公开的MIT-BIN数据集上进行实验,证明所提方法的有效性和优越性。

1 方法

在心律失常识别领域,可变持续时间ECG数据的采集方式和数据特点与传统图像数据不同,需要进行特殊处理和建模。此外,ECG信号中蕴含着重要的时序信息,这增加了建模的难度。因此,本文提出一种基于CWT和HOS的心律失常识别算法,旨在克服这些问题并提高ECG识别的准确率和鲁棒性。模型的总体框架如图1所示。首先,对原始信号进行去噪和分割处理,然后使用两个单独的网络对处理后的信号进行特征提取,每个网络提取不同模式下的特征信息,最后通过一个可学习的融合层进行后期融合。

1.1 数据预处理

临床采集的ECG信号通常会受到各种噪声的干扰,如基线漂移、肌电图干扰和电源线干扰,这使得很难从原始ECG信号中提取有用的信息。因此,在进一步处理之前需要噪声过滤。由呼吸或患者运动引起的基线漂移对ECG分类有重要影响,本文对噪声基线漂移进行滤波处理。在先前工作的基础上,采用两个中值滤波器(即200 ms和600 ms的中值滤波器)实现基线漂移,然后将其从原始信号中滤除以产生基线校正的ECG信号。图2a和图2b分别显示滤波前后噪音去除的效果,可以发现预处理后的信号更加简洁清晰。与常规无限脉冲响应和有限脉冲响应等其他滤波技术相比,中值滤波器可以在不增加相位失真的情况下消除异常值。由于可变持续时间ECG数据的采集方式和数据特点与传统图像数据不同,在心律失常分类之前,需要从心电信号中分离单个心跳。首先采用RR间期插值法,将处理后的数据转化为等长的信号序列,这通常需要准确检测QRS波和心跳的基准点。目前有许多高精度QRS波和基准点定位方法,已经有文献[20-25]证明QRS波和基准点定位方法对识别性能有重要的影响。在本文中,将带注释的R峰值位置作为基准点,并将心电信号分割成一系列心跳信号节拍。对于每个心跳,分别在R峰值之前采集100个样本,之后采集200个样本,获得固定大小的300个样本的心电信号。这些采样点捕捉到了最重要的心跳波,图2c显示了分割的结果。

1.2 基于CWT-CNN模型

为了应对心电信号具有较高的时频分辨率,本文提出一种基于CWT和CNN相结合的CWT-CNN模型。首先,采用CWT将心电信号分解为不同的时

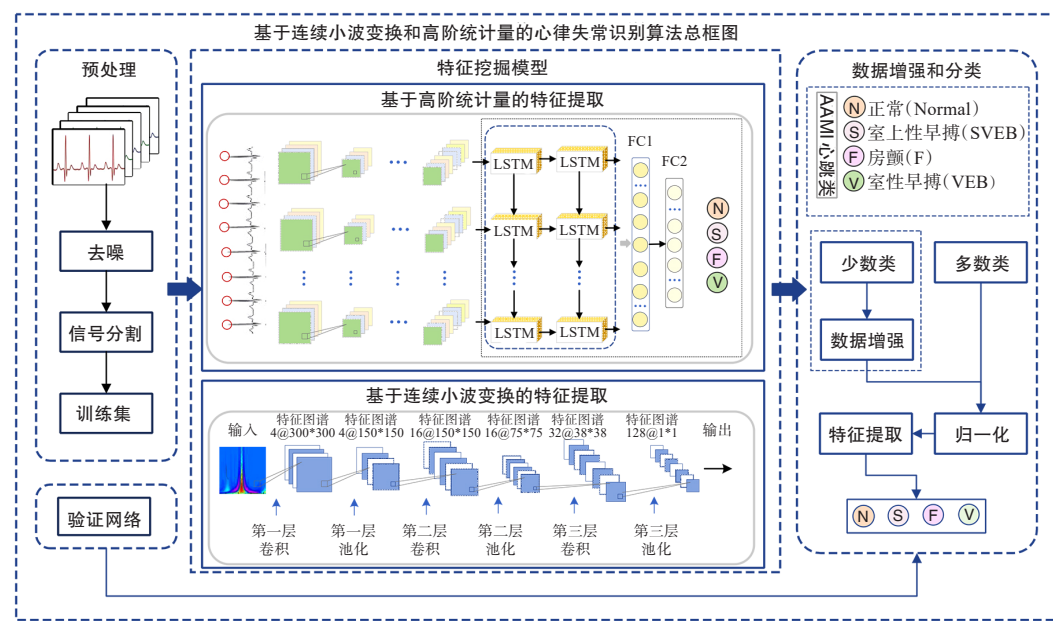


图1 心律失常识别算法总体框架图

Figure 1 Overall framework of the arrhythmia identification algorithm

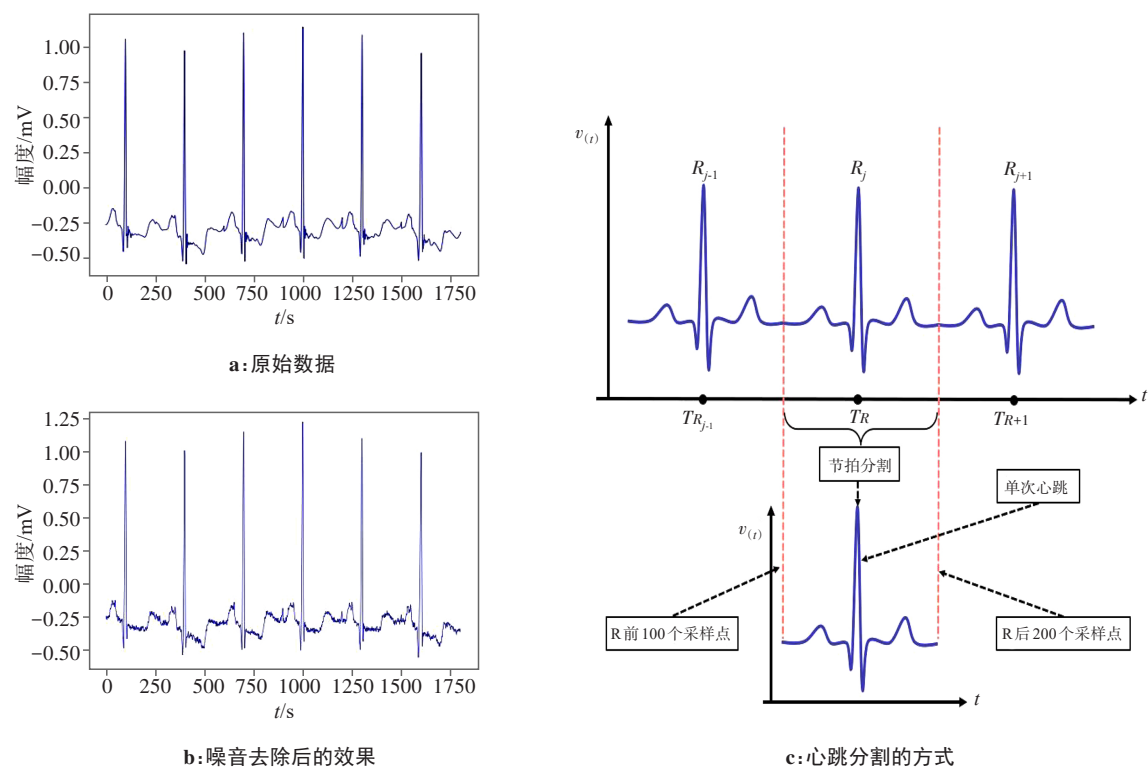


图2 数据预处理可视化

Figure 2 Data preprocessing visualization

频分量。通过这种分解,能够更好地捕捉心电信号中的时间和频率特征。CWT是最常用的时频分析工具,使用一系列小波函数在时频域中分解信号。它继承并发展了短时傅里叶变换的定位思想,通过调整尺度和平移参数,在高频中提供高时间分辨率和低频分辨率,在低频中提供高频分辨率和低时间分

辨率。形式上,给定信号 $x(t)$ 的CWT定义为:

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

其中, a 是尺度参数, b 是平移参数,而 $x(t)$ 是小波函数(也称为基小波)。该尺度变换通过:

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

将原始数据转换到频域,其中 F_c 是基小波的中心频率, f_s 是信号 $x(t)$ 的采样频率。其中,基小波的选择往往对时频分析的效果至关重要。在本研究中,采用墨西哥帽小波为基小波,因为它接近QRS波的形状,并被广泛用于ECG信号分析,其定义为:

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

利用CWT的不同尺度因子,得到信号在不同尺度下的小波系数。这些小波系数可以被视为ECG信

号在时频域中的二维尺度图。图3分别显示正常心跳、室性早搏、室上性早搏和房颤的时域ECG心跳信号和标度图。这4种信号均有300个采样点,并以360 Hz的频率采样,由墨西哥草帽小波分解。从标度图可以看出,室性早搏心跳与正常心跳明显不同。这表明可以使用尺度图进行心跳分类。然而,很难明确建立尺度图与异常条件之间的关系。为了解决这个问题,本研究构建一种基于CWT和CNN模型的特征提取模型用于挖掘不同心律失常和正常心跳之间的潜在关系,该模型的具体参数如表1所示。

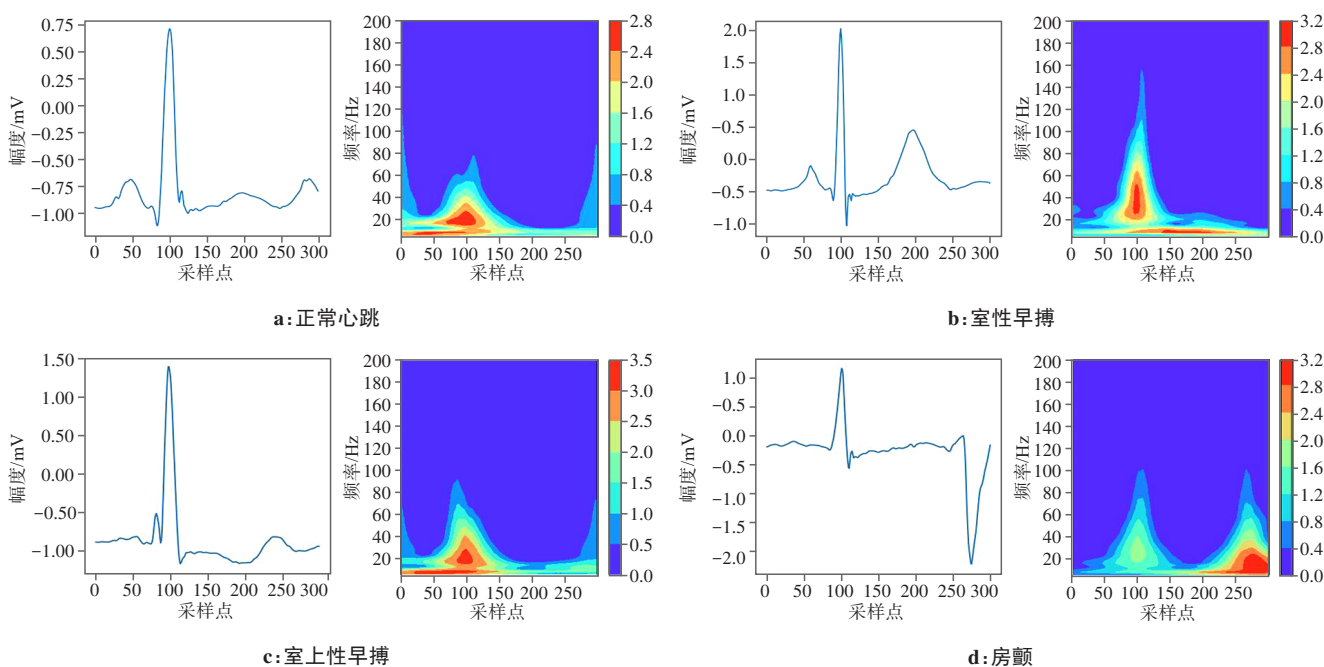


图3 4种原始心电图心跳信号及其CWT尺度图

Figure 3 Four original ECG heartbeat signals and their CWT scalograms

1.3 RRHOS-LSTM模型

RRHOS-LSTM模型由特征提取层和LSTM组成,其基本网络结构如图4所示。特征提取过程包括RR间隔和HOS两个部分,RR间隔部分从RR间隔中提取8个特征,以揭示关于两个连续心跳R峰的全局和局部信息。HOS部分测量输入心跳的高阶统计特征,包括偏度和峰度,以衡量心跳的锐度和不对称性。相比于形态学ECG数据,HOS提取的特征更加丰富。HOS从5个连续心跳(2个前心跳和2个后心跳伴随当前心跳)中提取60个特征,LSTM的输入特征个数为68,对输入特征进行处理,学习时间动态。在LSTM后面添加20%的Dropout层,以减少模型过拟合。每个时间步长产生LSTM的输出隐藏状态,并

将其传递给Softmax层对电信号进行分类。通过采用构建的RRHOS-LSTM模型,能够充分考虑到可变持续时间ECG数据中的时序特性,并将其有效地应用于特征提取和建模过程中。这种方法能够更准确地捕捉ECG中的重要信息,并提高ECG识别的性能。

1.4 网络融合与验证

多模式特征的有效融合是提高网络性能的关键,本文提出一种自适应参数融合网络,可以有效地融合CWT-CNN模型和RRHOS-LSTM模型提取特征的多样性,进一步提高多模式特征提取网络的性能。将第 v 个特征提取网络经过自适应平均池化层和整形函数依次处理后的特征映射记为 f_v^v ,那么多模式特

表 1 CWT-CNN 模型架构参数
Table 1 Architecture parameters of CWT-CNN model

No.	卷积层	卷积核大小	卷积核个数	填充	步幅	输出形状	参数数量
1	Input1*	-	-	-	-	100×100×1	-
2	Conv2D	7×7	16	0	1	94×94×16	784
3	Batch Normalization	-	-	-	-	94×94×16	64
4	Relu	-	-	-	-	94×94×16	-
5	Max pooling	5×5	-	0	5	18×18×16	-
6	Conv2D	3×3	32	0	1	16×16×32	4608
7	Batch Normalization	-	-	-	-	16×16×32	128
8	Relu	-	-	-	-	16×16×32	-
9	Max pooling	3×3	-	0	3	5×5×32	-
10	Conv2D	3×3	64	0	1	3×3×64	18432
11	Batch Normalization	-	-	-	-	3×3×64	256
12	Relu	-	-	-	-	3×3×64	-
13	Globel Max pooling	3×3	-	-	-	1×1×64	-
14	Flatten	-	-	-	-	64	-
15	Input2**	-	-	-	-	4	-
16	Concatenate	-	-	-	-	68	-
17	Dense	-	-	-	-	32	2208
18	Dense	-	-	-	-	4	132




图 4 RRHOS-LSTM 模型的网络架构图
Figure 4 Network architecture of RRHOS-LSTM model

征融合的输出 f_o 可以表示为：

$$f_o = \sum_{v=1}^V \sigma(F_c^v(f_r^v))$$

(4)

其中, v 为特征提取模型的个数总数,本文设置 $v=2$, σ 为 Sigmoid 激活函数, F_c^v 为全连接层, c 为特征通道数。用于多模型特征融合的网络如图 5 所示。

1.5 加权交叉熵损失函数

由于 ECG 数据分布高度不平衡,对少数类进行过度采样可能会导致过拟合,并增加训练模型的时间复杂度,因此使用加权损失函数来鼓励每个模型更加关注少数类。在本文中,使用加权交叉熵作为

全连接层的损失函数。加权交叉熵损失函数 L 可以定义为：

$$L = - \sum_{c=1}^M \beta_c y_{o,c} \log(p_{o,c})$$

(5)

其中, β_c 是 c 类的权重函数, $y_{o,c}$ 是真值二进制指示符, $p_{o,c}$ 为观测值 o 被分类为 c 的预测值。权重 β_c 基于样本频率定义如下：

$$\beta_c = \frac{F_j}{F_c}$$

(6)

其中, F_j 是多数类的样本数, F_c 是类 c 的样本数。这里使用的比例是 1:4,意味着阴性样本的数量是阳性




图5 多特征融合的网络架构图
Figure 5 Network architecture for multi-feature fusion

样本的4倍。加权交叉熵损失函数对于确保模型是学习少数类而不是被多数类过度拟合非常重要。

2 结果与分析

2.1 数据集

本文提出方法的评估基准数据集是著名的MIT-BIH心律失常数据库^[12]。该数据库包含47位受试者的48个0.5 h记录。从4 000个24 h动态ECG记录中随机选择23个记录,作为常规临床情况的代表性样本。剩下的25个记录也是从上述动态ECG记录中获得,其中包含罕见但临床意义重大的心律失常。每个记录包括两个导联(称为导联A和导联B),每秒360个样本,ECG信号范围为10 mV,具有11位分辨率。导联A对应于改良导联II(MLII),而导联B则根据记录的情况而定,包括导联VI、VII、V2、V4或V5。由于MLII在所选记录中普遍使用,本文中使用MLII进行ECG分类。这些记录由两名或多名心脏专家独立标注,并被归类为15种心律失常类型。根据医疗器械进步协会(AAMI)的建议,将这些心律失常进一步分为5类,如表2所示,并排除具有起搏搏动的4个记录(即102、104、107和217)。此外,由于实际上不存在Q类心律失常,本研究像其他研究一样忽略了它^[22]。

表2 MIT-BIH 心律失常数据库心跳类型到AAMI心跳类的映射

Table 2 Mapping of MIT-BIH arrhythmia database heartbeat types to AAMI heartbeat classes

正常心跳(N)	室上性异常搏动(A)	室性异常搏动(V)	融合节拍(F)	未能分类的节拍(Q)
正常节拍(或非)(N)-N	房性早搏(AP)-A	室性早搏收缩(PVC)-V	心室融合(fVN)-F	节奏节拍(P)-/
左束支传导阻滞(LBBB)-L	变异性房性早搏(aAP)-a	心室逸搏(VE)-E	-	节奏和正常节拍的融合(fPN)-f
右束支传导阻滞(RBBB)-R	节点早搏(NP)-J	-	-	未分类节拍(u)-Q
心房异搏(AE)-e	室上性早搏(SP)-S	-	-	
节点逃逸拍(NE)-j	-	-	-	

如上所述,本文关注的是方法在患者之间的表现。为了与现有研究进行直接比较,采用de Chazal等^[3]提出广泛使用的数据分割方法对MIT-BIH心律失常数据库进行分割。将数据库分为DS1和DS2两个数据集,每个数据集包含22个具有相似心跳类型比例的记录。第一个数据集用于训练,第二个数据集用于评估该方法的性能。两个数据集中不包含同一患者。

2.2 评价指标

本文使用4个指标对所提方法的性能进行评估。这些指标包括准确率(Acc)、F1值、灵敏度(Sen)和精确度(Ppv),定义如下:

$$\text{Acc} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (7)$$

$$\text{F1} = 2 \times \frac{\text{Ppv} \times \text{Sen}}{\text{Ppv} + \text{Sen}} \quad (8)$$

$$\text{Sen} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (9)$$

$$\text{Ppv} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (10)$$

其中,TP(True Negative)指的是被正确地判断为正例样本的心跳数;FP(False Positive)表示实际为负例样本被错误地判断为正例的心跳数;FN(False Negative)被定义实际为正例样本被错误地判断为负例的心跳数;TN(True Negative)表示被正确地判断为负例样本的心跳数。

2.3 实验环境与参数设置

本文在 Tesla V100-SXM2 图形处理单元上进行实验,主要环境配置和参数如表3所示。选择交叉熵作为损失函数,并采用 Adam 优化器进行训练。卷积层和全连接层的权重采用核初始化方法进行初始化。初始学习率设置为 0.001,每 5 个 epochs 降低为原来的 0.1 倍。模型的批量大小为 128,最大 epochs 设置为 30。使用 TensorFlow 2.0 实现深度卷积网络。

表 3 模型训练超参数
Table 3 Hyperparameters for model training

参数	取值
optimizer	Adam
epochs	30
batch_size	128
loss	sparse_categorical_crossentropy
wfdb	4.1.0
TensorFlow	2.0
CUDA	10.2
cuDNN	7.6.5

2.4 消融实验与结果分析

为了提升心律失常识别的准确率,本文提出一种基于 CWT 和 HOS 的心律失常识别算法模型。该模型利用了卷积网络在基于 CWT 和 HOS 的特征表示方面的能力,以识别不同类型的心率失常。为了验证该模型的性能,本文进行以下消融实验以对其结果进行分析。由于小波函数的选择对 CWT 具有重要影响。因此,本文首先探究不同小波类型对性能的影响。在信号分析中,CWT 是最常用的信号分析工具之一,但是小波函数的选择并没有一个统一的标准。为了充分验证基小波的种类对模型特征提取性能的影响,在本文中,除了墨西哥草帽小波(mexh)之外还分析了 3 种广泛应用于 ECG 信号的小波函数,包括 Morlet 小波(morl)、高斯小波(gauss8, gauss4),以研究小波函数类型对分类结果的影响。在表 4 中列出 4 种小波函数的总体性能指标。mexh 在精确度、F1 值和准确率方面取得最佳表现,只是灵敏度略低于 gauss4。

为了探究这一结果背后的原因,本文绘制了这些小波函数的波形,如图 6 所示。研究发现,在这些小波函数中, mexh 的波形最接近 ECG 信号的波形,其次是 gauss4,而 gauss8 和 morl 与 ECG 信号的波形差异较大。分析发现 ECG 信号的波形与小波函数之

表 4 4 种小波函数的整体分类性能比较(%)
Table 4 Overall classification performance comparison among 4 wavelet functions (%)

小波函数类型	精确度	灵敏度	F1 值	准确率
mexh	70.75	67.47	68.76	98.74
morl	61.68	67.13	63.54	97.65
gauss8	67.23	66.97	65.63	98.14
gauss4	65.33	68.18	66.56	98.30

间的相似度越高,性能越好。因此,在执行类似 ECG 信号分析时,建议使用与信号相似度较高的小波函数。

为探究联合模型较单一分类模型的优越性,本文对单个 CWT-2DCNN、RRHOS-LSTM 和 CWITHOS-Net 模型在 MIT-BIH 数据库下进行消融实验,以确认所提出的联合 CWITHOS-Net 模型对 ECG 信号分类的有效性。如表 5 所示,在 MIT-BIH 数据集上,联合 CWITHOS-Net 模型的整体性能优于单一 CWT-2DCNN 模型和 RRHOS-LSTM 模型。

为了验证模型的优越性,根据 AAMI 的建议^[9],本文对 MIT-BIH 心律失常数据库的心跳进行分组,将数据库划分为 DS1 和 DS2 数据集。DS1 用于训练,DS2 用于测试。为了进行公平的比较,在本研究中,仅将其与使用相同策略的方法进行比较,以进一步证实所提出的联合网络模型分类算法的有效性。表 6 显示了本研究 and 现有研究方法性能比较,可以看出所提出模型 的分类精确率和 F1 值均优于其他方法。除正常心跳类和融合节拍类外,本文所提出的方法在所有其他类别度量中取得了最佳性能。例如,与性能最好的 Hu 等^[26]提出的 ResNet-TCN 模型相比,本文所提出的方法在室上性异位搏动类、室性异位搏动类和融合节拍类中的灵敏度分别提高 4.3%、1.2%、1.6%;精确度分别提高 8.5%、0.3%、2.5%。除了正常心跳类之外,本文方法在其他类中取得更好或可比较的性能。造成这种结果的原因是本文提出的方法在训练分类过程中采用加权损失函数来处理 MIT-BIN 数据集的不均衡性。这削弱了正常心跳类作为多数类的优势,使得对其单独的性能度量降低。帮助了少数类,使得少数类的度量性能得到提升,整体的准确率和 F1 值分别提升到 99.2% 和 96.3%。特别是,本文方法总体 F1 值提高 3.2%~5.2%。

对于融合节拍类,该类心律失常是由心房快速而不规则跳动引起的。房颤是一种复杂的心律失常,它的特征提取比其他类型的心律失常更具挑战性,又加上在 MIT-BIH 心律失常数据库中的比例相

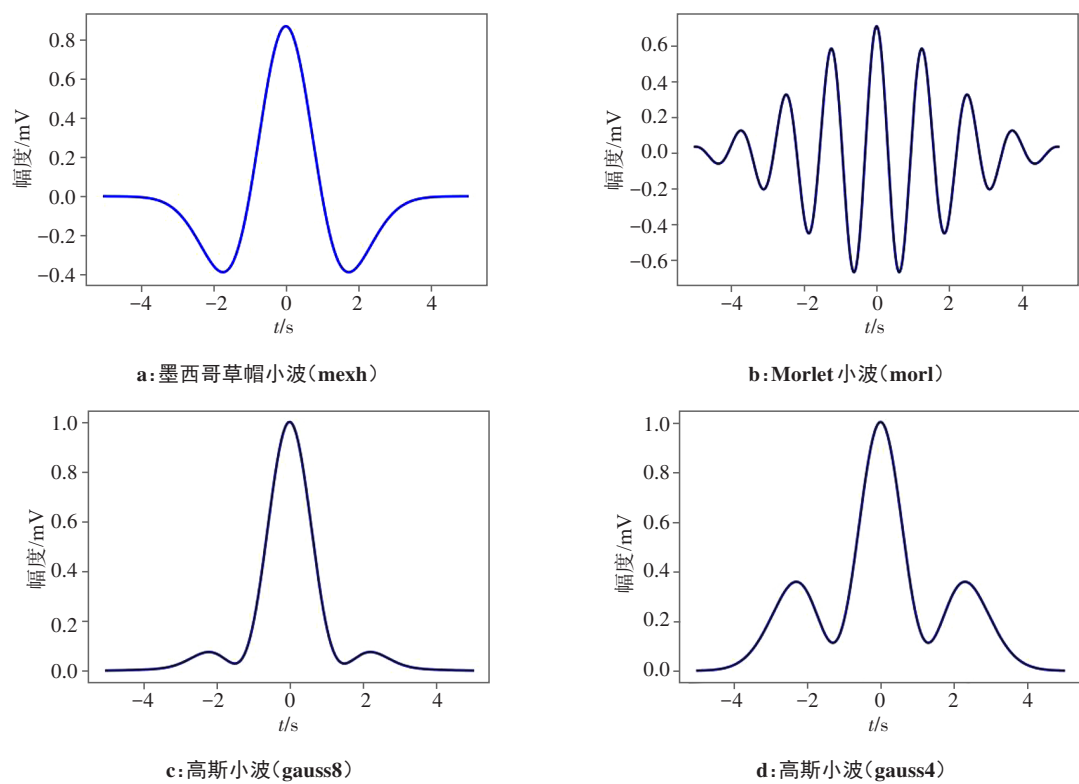


图6 4种类型的基小波

Figure 6 Four types of wavelet functions

表5 CWTNOS-Net模型与单一分类模型的性能比较

Table 5 Performance comparison between CWTNOS-Net model and single classification models

分类器	准确率	灵敏度	精确度	F1值
CWT-2DCNN	0.988	0.961	0.964	0.961
RRHOS-LSTM	0.989	0.987	0.961	0.961
CWTNOS-Net	0.992	0.988	0.963	0.963

对较少,仅占总数据量约16%,这也就导致模型在识别房颤时出现度量指标低的情况。在本研究中,使用高阶统计信息进行特征提取分析,来解决房颤ECG信号在时间和频率上的变化较快的问题,但融合节拍类的数量有限,因此引入加权损失函数对数据集做数据增强处理。这使得本文方法对于融合节拍类呈现出更好的结果。

表6 本研究 and 现有研究方法的分类性能比较

Table 6 Classification performance comparison between the proposed method and the existing methods

模型	准确率	F1值	正常心跳		室上性异位搏动		室性异位搏动		融合节拍	
			灵敏度	精确度	灵敏度	精确度	灵敏度	精确度	灵敏度	精确度
Acharya等 ^[13]	0.940	0.924	0.916	0.852	0.890	0.948	0.941	0.951	0.952	0.947
Zhu等 ^[22]	0.978	0.911	0.992	0.985	0.875	0.953	0.947	0.952	0.739	0.861
Hua等 ^[24]	0.974	0.931	0.965	0.971	0.928	0.957	0.928	0.964	0.836	0.904
Gai ^[25]	0.986	0.912	0.996	0.990	0.797	0.906	0.959	0.971	0.846	0.840
Hu等 ^[26]	0.988	0.925	0.994	0.994	0.917	0.890	0.968	0.969	0.783	0.882
本文方法	0.992	0.963	0.980	0.958	0.960	0.975	0.980	0.972	0.799	0.907

在特征学习方面,本研究基于深度学习的方法可以自动从数据中提取判别特征。为了验证特征提取能力,使用t分布随机邻居嵌入(t-SNE)来可视化

提取ECG特征。图7显示原始尺度图和从4个卷积单元获得的表示特征的t-SNE。为了实现良好的可视化效果,可视化过程中减少图中的样本数量。从

图 7a 中可以看出,原始尺度图中不同类型的心跳混合在一起,并且存在一些异常值,特别是红色标签代表的正常类,这是由于心率失常的特性导致的,心率失常的心跳形状发生细微变化,导致其与正常类的心跳混淆。在卷积单元中,随着层次的加深,异常值

逐渐减少,心跳得到更好的聚集。图 7d 所示最后一个卷积单元中,不同类型的心跳已经得到明显的聚类,特别是正常类心跳被有效地区分出来。这表明多模式深度卷积模型可以有效地提取特征,并且随着网络深度的增加,所提取的特征更具有辨别能力。

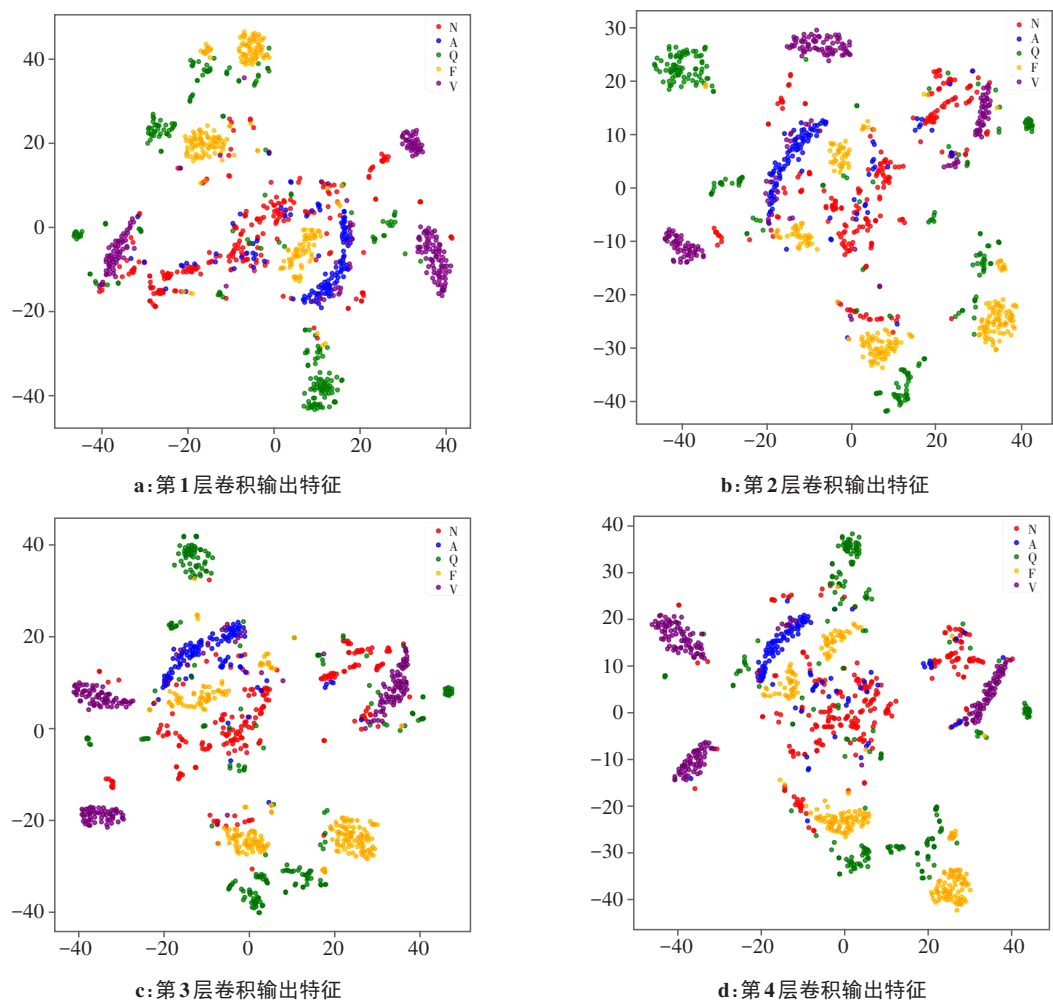


图 7 模型输出层特征的 t -SNE
Figure 7 Visualization of t -SNE for model output layer features

3 结 论

本文提出一种基于 CWT 和 HOS 的心律失常识别算法,该方法将 ECG 心跳信号转换到时频域以避免不同频率分量的混叠效应,然后使用 CNN 从分解后的时频分量组成的尺度图中提取特征,充分利用 CWT 在多维信号处理和 CNN 在图像识别方面的优势。此外,为了充分利用 ECG 中的时序信息,使用 RR 间隔和 HOS 作为补充特征,结合 LSTM 模型来获取时序信息。通过在 MIT-BIH 心律失常数据库上使用患者间样本进行测试,该方法的精确度、灵敏度、F1 值和准确率的总体表现分别为 96.3%、98.8%、96.3% 和 99.2%。与单一模型相比,本文提出的多模

式模型在准确率和 F1 值方面具有一定的优越性。接下来更进一步的研究可以聚焦将网络扩展到其他相关的识别任务,例如心脏疾病和人物识别等方面。

【参考文献】

[1] Wang T, Lu CH, Sun YN, et al. Automatic ECG classification using continuous wavelet transform and convolutional neural network[J]. Entropy (Basel), 2021, 23(1): 119.
[2] 刘建华, 吕建峰, 蔡金丹. 基于卷积神经网络和长短时记忆网络的心肌梗死检测[J]. 中国医学物理学杂志, 2022, 39(11): 1448-1452.
Liu JH, Lü JF, Cai JD. Screening for myocardial infarction using convolutional neural network and long short-term memory network [J]. Chinese Journal of Medical Physics, 2022, 39(11): 1448-1452.
[3] de Chazal P, O'Dwyer M, Reilly RB. Automatic classification of heartbeats using ECG morphology and heartbeat interval features[J]. IEEE Trans Biomed Eng, 2004, 51(7): 1196-1206.

- [4] Gaurav K, Goyal V, Saini N. Arrhythmia classification using support vector machine and decision tree[J]. International Journal of Scientific Research in Computer Science and Engineering (IJSRCSEIT), 2018, 6(3): 33-38.
- [5] Khalaf AF, Owis MI, Yassine IA. A novel technique for cardiac arrhythmia classification using spectral correlation and support vector machines[J]. Expert Syst Appl, 2015, 42(21): 8361-8368.
- [6] Tao X, Gao L, Li Y, et al. Multi-view deep learning for automated ECG classification[J]. J Ambient Intell Humaniz Comput, 2018, 9(6): 1933-1942.
- [7] Li C, Zheng Y, Liu Y, et al. Multi-view deep learning for ECG classification [C]//Proceedings of the 2018 International Joint Conference on Neural Networks (IJCNN). 2018: 1-7.
- [8] Daubechies I. The wavelet transform, time-frequency localization and signal analysis[J]. IEEE Trans Inf Theory, 1990, 36(5): 961-1005.
- [9] Wang X, Zhang X, Cheng F, et al. An optimized linear discriminant analysis algorithm for ECG classification[J]. J Healthc Eng, 2019, 6(19): 1-11.
- [10] Abbas Q, Khan AM, Ullah I. ECG signal classification using linear discriminant analysis and unsupervised feature learning[J]. Biomed Signal Process Control, 2019, 53(2): 101580.
- [11] Yıldırım Ö, Pławiak P, Tan RS, et al. Arrhythmia detection using deep convolutional neural network with long duration ECG signals[J]. Comput Biol Med, 2018, 102: 411-420.
- [12] Moody GB, Mark RG. The impact of the MIT-BIH arrhythmia database [J]. IEEE Eng Med Biol Mag, 2001, 20(3): 45-50.
- [13] Acharya UR, Oh SL, Hagiwara Y, et al. A deep convolutional neural network model to classify heartbeats[J]. Comput Biol Med, 2017, 89: 389-396.
- [14] Hou BR, Yang JY, Wang P, et al. LSTM-based auto-encoder model for ECG arrhythmias classification[J]. IEEE Trans Instrum Meas, 2020, 69(4): 1232-1240.
- [15] Jyotishi D, Dandapat S. An LSTM-based model for person identification using ECG signal[J]. IEEE Sensors Letters, 2020, 4(8): 1-4.
- [16] Chen TM, Huang CH, Shih ES, et al. Detection and classification of cardiac arrhythmias by a challenge-best deep learning neural network model[J]. iScience, 2020, 23(3): 100886.
- [17] Wang JK, Qiao X, Liu CC, et al. Automated ECG classification using a non-local convolutional block attention module[J]. Comput Methods Programs Biomed, 2021, 203: 106006.
- [18] Strodthoff N, Wagner P, Schaeffter T, et al. Deep learning for ECG analysis: benchmarks and insights from PTB-XL[J]. IEEE J Biomed Health Inform, 2021, 25(5): 1519-1528.
- [19] 吕杭, 蒋明峰, 李杨, 等. 基于混合时频域特征的卷积神经网络心律失分类方法的研究[J]. 电子学报, 2023, 51(3): 701-711.
- [19] Lü H, Jiang MF, Li Y, et al. Research on arrhythmia classification by using convolutional neural network with mixed Time-Frequency domain features[J]. Acta Electronica Sinica, 2023, 51(3): 701-711.
- [20] 徐柏林, 蔡文杰, 杨明菲, 等. 基于改进 U-Net 模型的心电波形分割[J]. 中国医学物理学杂志, 2022, 39(10): 1274-1279.
- [20] Xu BL, Cai WJ, Yang MF, et al. ECG waveform segmentation based on improved U-Net model[J]. Chinese Journal of Medical Physics, 2022, 39(10): 1274-1279.
- [21] Li W, Li B, Meng HL, et al. The QRS complex detection of ECG signal based on IPCMM algorithm [C]//2020 39th Chinese Control Conference (CCC). Piscataway, NJ, USA: IEEE, 2020: 6225-6230.
- [22] Zhu WL, Chen XH, Wang Y, et al. Arrhythmia recognition and classification using ECG morphology and segment feature analysis[J]. IEEE/ACM Trans Comput Biol Bioinform, 2019, 16(1): 131-138.
- [23] Palma LD, D'Alessandro VI, Attivissimo F, et al. ECG wave segmentation algorithm for complete P-QRS-T detection[C]//2023 IEEE International Symposium on Medical Measurements and Applications (MeMeA). Piscataway, NJ, USA: IEEE, 2023: 1-6.
- [24] Hua X, Han JG, Zhao C, et al. A novel method for ECG signal classification via one-dimensional convolutional neural network[J]. Multimed Syst, 2022, 28(4): 1387-1399.
- [25] Gai ND. ECG beat classification using machine learning and pretrained convolutional neural networks[J]. Comput Biol Med, 2022, 22(1): 06408-06419.
- [26] Hu SG, Li RW, Hu Q, et al. ResNet-TCN: a joint model for ECG heartbeat classification with high accuracy[C]//2023 International Conference on Information Networking (ICOIN). Piscataway, NJ, USA: IEEE, 2023: 467-471.

(编辑:陈丽霞)