

基于一维卷积特征与手工特征融合的集成超限学习机心跳分类方法

许超凡^{1,2)}, 肖文栋^{1,2,3)}, 曹征涛⁴⁾✉

1) 北京科技大学自动化学院, 北京 100083 2) 北京市工业波谱成像工程技术研究中心, 北京 100083 3) 北京科技大学顺德研究生院, 顺德 528399 4) 空军特色医学中心, 北京 100142

✉通信作者, E-mail: czhengtao@126.com

摘 要 融合手工特征和深度特征, 提出了一种集成超限学习机心跳分类方法。手工提取的特征明确地表征了心电信号的特定特性, 如相邻心跳时间间隔反映了心跳信号的时域特性, 小波系数反映了心跳信号的时频特性。同时设计了一维卷积神经网络对心跳信号特征进行自动提取。基于超限学习机(Extreme learning machine, ELM), 将上述特征融合进行心跳分类。由于 ELM 初始参数的随机给定可能导致其性能不稳定, 进一步提出了一种基于袋装(Bagging)策略的多个 ELM 集成方法, 使分类结果更加稳定且模型泛化能力更强。利用麻省理工心律失常公开数据集对所提方法进行了验证, 分类准确率达到 99.02%, 实验结果也表明基于融合特征的分类准确率高于基于单独特征的分类准确率。

关键词 心跳分类; 特征融合; 一维卷积神经网络; 小波变换; 集成超限学习机

分类号 TP182

Ensemble extreme learning machine approach for heartbeat classification by fusing 1d convolutional and handcrafted features

XU Yue-fan^{1,2)}, XIAO Wen-dong^{1,2,3)}, CAO Zheng-tao⁴⁾✉

1) School of Automation & Electrical Engineering, University of Science and Technology Beijing, Beijing 100083, China

2) Beijing Engineering Research Center of Industrial Spectrum Imaging, Beijing 100083, China

3) Shunde Graduate School, University of Science and Technology Beijing, Shunde 528399, China

4) Air Force Medical Center, PLA, Beijing 100142, China

✉ Corresponding author, E-mail: czhengtao@126.com

ABSTRACT Arrhythmia is a common cardiovascular disease whose occurrence is mainly related to two factors: cardiac pacing and conduction. Some severe arrhythmias can even threaten human life. An electrocardiogram (ECG) records the changes in electrical activity generated during each cardiac cycle of the heart, which can reflect the human cardiac health status and help diagnose arrhythmias. However, because of the brevity of conventional ECGs, arrhythmias, which occasionally occur in daily life, cannot be detected easily. Automatic ECG analysis-based long-term heartbeat monitoring is of great significance for the effective detection of accidental arrhythmias and then for taking indispensable measures to prevent cardiovascular diseases in time. An ensemble extreme learning machine (ELM) approach for heartbeat classification that fuses handcrafted features and deep features was proposed. The manually extracted features clearly characterize the heartbeat signal, where RR interval features reflect the time-domain characteristic, and the wavelet coefficient features reflect the time–frequency characteristic. A 1D convolutional neural network (1D CNN) was

收稿日期: 2021–01–12

基金项目: 国家重点研发计划课题资助项目(2017YFB1401203); 佛山市科技创新专项资金资助项目(BK20AF005)

designed to automatically extract deep features for heartbeat signals. These features were fused by an ELM for heartbeat classification. Because of the instability caused by the random assignment of ELM hidden layer parameters, the bagging ensemble strategy was introduced to integrate multiple ELMs to achieve stable classification performance and good generalization ability. The proposed approach was validated on the MIT-BIH arrhythmia public dataset. The classification accuracy reaches 99.02%, and the experimental results show that the performance of the proposed approach with fused features is better than those with only deep features and only handcrafted features.

KEY WORDS heartbeat classification; feature fusion; 1D convolutional neural network; wavelet transform; ensemble extreme learning machine

心律失常是由心脏电脉冲的频率、规律性、起搏位置或者传导的紊乱引起的^[1]。严重的心律失常甚至会威胁人类的生命。心电图(Electrocardiogram, ECG)记录了人体心脏每一个心动周期所产生的电活动变化,是医生诊断心律失常的重要依据。由于心律失常种类繁多,表现复杂,识别心律失常往往需要有丰富经验的医生。而且,常规的心电图检查仅仅持续几分钟,一些偶然发生的不规则心律失常并不能被检查出来。例如心源性猝死这种心血管病,从发病到死亡持续时间短,基于传统的常规心电图检查方式缺乏实时性,往往会耽误病人最好的治疗时间。

动态心电图监测仪(Holter),是由 Norman J. Holter 于 1949 年发明的可穿戴设备,它能够连续监测病人日常生活中 24 h 甚至更长时间的心脏电活动,这种长时程的记录有助于监测偶然发生的心律失常。因此,基于动态心电图的自动心律失常分类方法对于及时发现和预防心血管疾病有着重要的意义。

影响心电信号自动分类系统性能主要有两个因素,一是心电信号特征的提取,二是分类器的选择。特征提取的质量对心跳分类性能具有至关重要的影响,提取的特征对于不同类别的心律失常应具有更好的离散性,而对同类心律失常具有相似性。传统的心律失常分类方法使用手工提取的特征,其特征是可解释的。之前的文献针对心电信号已经提取了各种各样的特征,包括相邻心跳时间间隔特征(RR Intervals)^[2-3]、形态学特征^[4]、小波特征^[5-6]、高斯混合模型特征^[7]和高阶统计量^[8]等。对于心律失常分类任务,支持向量机^[9]、 k 近邻^[10]等分类器已经被使用。

近年来,由于自动提取特征的优势,学者们广泛研究了卷积神经网络(Convolutional neural network, CNN),提出了各种不同结构的 CNN^[11-14],并成功应用于不同领域,包括人脸识别^[15-17]、语义分割^[18]等。这种方法的特点是,具有原始结构的

数据可直接输入到 CNN 中,利用 CNN 的逐层卷积操作,提取深层的特征,形成原始信号的抽象表示^[19]。

对于分类任务,往往通过在 CNN 网络最后一层增加 softmax 层实现。CNN 网络参数的训练一般采用反向传播(Back propagation, BP)算法。但是,该算法容易陷入局部最优,且非常耗时。为解决上述问题,超限学习机(Extreme learning machine, ELM)被提出。ELM 是一种单隐含层前馈神经网络(Single hidden layer feedforward neural network, SLFN),其中隐含层参数是随机生成的,不需要调整,而输出参数通过最小二乘法解析得到^[20]。因此,其训练速度相比于 BP 算法是很快的。同时,ELM 具有万能逼近能力,也就是说,随着隐含层节点数的增加,网络能够以无限小的误差逼近非线性函数^[21]。

现有的心律失常分类方法往往只单独考虑手工提取的特征或者深度学习自动提取的特征,而融合深度卷积网络自动提取的特征和手工提取的特征对心跳信号的表示更全面,并能产生更好的分类性能。为此,本文提出了一种融合手工特征和深度特征的集成超限学习机心跳分类方法。我们设计了一种针对心跳信号分类的一维 CNN 结构,利用其多层卷积操作提取了心电信号的深层特征。另外又手工提取了心跳信号的特征,包括 RR 间期特征与小波系数特征。然后,我们融合这些特征并将其作为 ELM 的输入,进行分类。为了弥补 ELM 随机生成参数而导致的分类结果不稳定的缺陷,我们使用 Bagging 方法对多个 ELM 分类器进行集成,得到更好的分类结果。

1 基本算法

1.1 卷积神经网络

CNN 是一类包含卷积计算且具有深度结构的前馈神经网络,是深度学习的代表算法之一。不同维度的输入数据能够用不同类型的卷积来进行操

作. 二维卷积神经网络(2D CNN)由于其出色的自动特征提取功能已经成功应用于图像分类^[22-23]. 为了同时从空间和时间维度提取特征, 针对三维监控视频数据的三维卷积神经网络(3D CNN)被提出用来进行人类动作识别^[24]. 在我们的研究中, 心跳信号本质上是一维信号, 为了避免从一维到二维的转换, 保留数据的原始结构, 我们设计了一种针对心跳信号的一维卷积神经网络(1D CNN).

在 1D CNN 中, 卷积层的一维卷积操作用来从局部邻域提取特征. 特征映射的实现过程是由卷积核扫描其输入, 然后将其结果存储到相应的特征映射的位置. 卷积核大小相对于前一层的特征映射往往较小, 而且卷积层会有多个卷积核, 每一个都有不同的参数, 这样可以提取多个局部特征, 组成一系列的特征映射. 假设在第 i 层的第 j 个特征映射, 在位置 t 的单元的值表示为 v_{ij}^t , 其由下式计算

$$v_{ij}^t = \text{ReLU} \left(b_{ij} + \sum_{d=1}^D \sum_{s=0}^{S_i} w_{ijm}^s v_{(i-1)d}^{t+s} \right) \quad (1)$$

其中, $\text{ReLU}(\cdot)$ 为线性整流单元 (Rectified linear unit); b_{ij} 为对于第 j 个特征映射的偏置; D 为第 $(i-1)$ 层的通道数; d 为通道的序号; w_{ijm}^s 为第 i 层第 j 个特征映射的卷积核在位置 s 处的值, 且该卷积核连接到第 $(i-1)$ 层的第 m 个特征映射; S_i 为卷积核的大小.

在卷积神经网络的子采样层中, 特征映射的大小由对上一个卷积层的特征映射的局部邻域进行池化而减少. CNN 结构通过多个卷积和子采样堆叠而成.

1.2 超限学习机

ELM 是一个具有单隐含层的前馈神经网络, 它包含输入层、隐含层、输出层共三层, 其基本结构如图 1 所示. ELM 隐含层参数是随机生成的, 输出层参数基于最小二乘法解析得到. 这种训练方式是免迭代的, 避免了常规反向传播训练会陷入局部最优的缺点. 黄广斌等^[21]证明了 ELM 具有万能逼近能力. 具体地, 给定任何有界非常数的分段连续激活函数, 一个隐含层参数随机生成的网络, 仅仅通过调整其输出参数就能够以任意小的误差逼近目标函数.

假定我们有 N 个已标注的样本 $\mathbf{x}_i$, 其中 $i = 1, 2, \dots, N$ 且 $\mathbf{x}_i \in \mathbf{R}^n$. 对于有 L 个隐含层神经元的广义 SLFN, 由于隐含层参数是根据任意连续概率




图 1 ELM 的基本结构

Fig.1 Basic structure of an extreme learning machine (ELM)

分布随机生成, 那么隐含层输出矩阵 $\mathbf{H}$ 可以由如下公式计算得到

$$\mathbf{H} = \begin{bmatrix} g(\mathbf{a}_1 \cdot \mathbf{x}_1 + b_1) & \cdots & g(\mathbf{a}_L \cdot \mathbf{x}_1 + b_L) \\ \vdots & \ddots & \vdots \\ g(\mathbf{a}_1 \cdot \mathbf{x}_N + b_1) & \cdots & g(\mathbf{a}_L \cdot \mathbf{x}_N + b_L) \end{bmatrix}_{N \times L} \quad (2)$$

其中, $g(\cdot)$ 为激活函数, $\mathbf{a}_i$ 和 b_i 为隐含层中第 i 个节点的参数. 原始数据从输入层到隐含层的传播实际上是将数据从 n 维空间映射到了 L 维空间. 隐含层输出矩阵和网络输出矩阵之间的关系写成矩阵形式为

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T} \quad (3)$$

其中,

$$\boldsymbol{\beta} = \begin{bmatrix} \beta_{11} & \cdots & \beta_{1m} \\ \vdots & \ddots & \vdots \\ \beta_{L1} & \cdots & \beta_{Lm} \end{bmatrix}_{L \times m}, \quad \mathbf{T} = \begin{bmatrix} t_{11} & \cdots & t_{1m} \\ \vdots & \ddots & \vdots \\ t_{N1} & \cdots & t_{Nm} \end{bmatrix}_{N \times m} \quad (4)$$

在实际中训练数据的数量与隐含层节点数量往往不相等, 也就是说, 隐含层输出矩阵 $\mathbf{H}$ 并不是一个方阵, 因此等式 (3) 的最小二乘解不唯一. Bartlett 指出, 对于前馈神经网络, 网络权重越小, 该网络的泛化性能越好^[25]. 因此, 输出参数 $\boldsymbol{\beta}$ 的最小范数的最小二乘解为

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^\dagger \mathbf{T} \quad (5)$$

其中, $\mathbf{H}^\dagger$ 为 $\mathbf{H}$ 的 Moore-Penrose 广义逆矩阵.

为了避免病态问题, 根据岭回归理论, 添加一个正数 C 到矩阵 $\mathbf{H}^T \mathbf{H}$ 或者 $\mathbf{H} \mathbf{H}^T$ 的对角线可解决. 这样, ELM 的求解问题变为

$$\text{Minimize: } l = \frac{1}{2} \|\boldsymbol{\beta}\|^2 + \frac{1}{2} C \|\mathbf{T} - \mathbf{H}\boldsymbol{\beta}\|^2 \quad (6)$$

然后, 对 $\boldsymbol{\beta}$ 求偏导, 并让其等于零, 那么 ELM 的输出参数即可由下式求得

$$\boldsymbol{\beta} = \left(\frac{\mathbf{I}}{C} + \mathbf{H}^T \mathbf{H} \right)^{-1} \mathbf{H}^T \mathbf{T} \quad (7)$$

2 提出的方法

本节将对所提出的特征融合集成 ELM 心跳分类方法进行详细论述。

2.1 总体结构

图 2 展示了所提方法的总体结构, 总共包括 4 个阶段, 分别为 ECG 信号预处理、心跳分割、特征提取和心跳分类。在预处理阶段消除了 ECG 信号的基线漂移。在心跳分割阶段将连续的 ECG 信

号分割为单个的心跳片段。特征提取阶段分为手工特征提取和深度特征提取。手工特征包括时域特征以及时频特征。同时使用 1D CNN 自动提取心跳信号的深度特征。我们融合手工提取的特征和深度特征, 将其作为一个心跳信号的新的特征表示。在心跳分类阶段, 为了提升 ELM 分类性能的稳定性, 采用 Bagging 集成方法组合多个 ELM 分类器, 最后以多数投票的方式得到最终的分类结果。




图 2 心跳分类算法总体结构

Fig.2 Overall structure of the heartbeat classification algorithm

2.2 手工特征提取

2.2.1 RR 间期特征提取

RR 间期特征反应了心跳在时间域的特性。总共 4 类 RR 间期信息被计算: 前 RR, 即当前心跳与前一个心跳的 R 峰的时间间隔; 后 RR, 即当前心跳与后一个心跳的 R 峰的时间间隔; 短期 RR 间期, 当前心跳的前十个 RR 间期的平均值; 长期 RR 间期, 当前心跳的前五分钟 RR 间期的平均值。

2.2.2 时频特征提取

小波变换是一种时间-频率分析方法, 它具有

多分辨分析的特点, 而且在时频两域都具有表征信号局部特征的能力。因此, 适合于分析非平稳的信号和提取信号的局部特征。离散小波变换 (Discrete wavelet transform, DWT) 是小波变换的一种, 它是将尺度参数和平移参数离散化。在本文中, 我们使用 DWT 作为特征提取器, 提取心跳信号的局部特征。小波类型选择 Daubechies 1 小波, 小波分解层数为五层。小波分解第五层的近似系数和细节系数被用来作为一个心跳片段的时频特征。

2.3 一维卷积神经网络

在图像分类中, 由于图像中蕴含的模式较为复杂, 2D CNN 往往需要较深的结构. 而对于 ECG 信号, 其网络的输入是分割后的心跳片段, 维度较低. 采用过深的网络结构可能会恶化分类性能且增加计算代价. 因此, 我们设计了一个具有较浅结构的 1D CNN, 总共有 7 层, 如图 3 所示. 模型包括三个卷积层, 两个子采样层, 一个全连接层和一个输出层. C1 是一个卷积层, 包括 30 个特征映射. 每个核的长度是 15, 连接到输入信号的相邻

15 个样本点. S2 是一个子采样层, 由执行在 C1 层特征映射上的最大池化操作得到. C3 也是一个卷积层, 包括 10 个特征映射. 每个核的长度为 4. S4 是子采样层, 由执行在 C3 层特征映射上的最大池化操作得到. 随后所有 S4 层的特征平铺成一个 350 维的特征向量, C5 层的特征作为对输入心跳信号的深层特征表示. 全连接层 F6 以及输出层共同执行分类任务. 输出层的神经元个数与待分类的心跳信号类别数量一致, 即 16 个输出层神经元.




图 3 本文提出的 1D CNN 结构

Fig.3 Structure of the proposed 1D convolutional neural network

损失函数选用交叉熵 (Cross entropy). 随机梯度下降用来训练神经网络的参数. 使用三种提升权重训练过程的方法, 分别为: 权值衰减 (Weight decay)、动量 (Momentum) 和随机失活 (Dropout). 权值衰减就是在权重更新规则中加入一个项使得权值指数地衰减到 0, 这个方法可以用来避免过拟合. Momentum 是一种加速梯度下降的技术, 对于那些当前的梯度方向与上一次梯度方向相同的参数进行加强, 即在这些方向上更快; 相反, 对于那些当前的梯度方向与上一次梯度方向不同的参数进行减弱, 即在这些方向上减慢. Dropout 是指在每次训练迭代中, 随机地从神经网络中消除一部分节点, 这也是一种避免过拟合的技术.

2.4 ELM 心跳分类

当手工特征和 1D CNN 的深度特征被提取出来后, 它们被整合到一起作为 ELM 的输入. 图 4 显示了基于单个 ELM 的心跳分类模型. 其中, 输入层是由手工特征包括 RR 间期特征和离散小波系数特征以及深度特征即 1D CNN 特征共同组成, 因此 ELM 输入层节点数等于所有这些特征的总个数. 输出层节点数等于待分类的心跳类别数.

2.5 Bagging 集成方法

由于 ELM 隐含层参数的随机分配, 其分类结果

也会存在一定的随机性. 为了提高 ELM 分类性能的稳定性和准确性, 我们采用 Bagging 集成学习方法将多个 ELM 分类器进行组合. 集成学习的关键在于构造具有差异性的弱分类器. 因此, 一方面, 在构造多个训练集时采用有放回采样 (Bootstrap), 即从训练样本中随机有放回抽样. 这意味着, 某一个训练样本可能多次出现在新构造的训练集中, 也有可能一次都不会选中. 上述方法是从数据集构造方面增加集成的多样性. 另一方面, 正因为 ELM 隐含层参数的随机初始化, 使得集成模型中每一个 ELM 模型都不相同, 同样增加了集成多样性.

当多个不同的训练集被构造出来后, 分别在这些训练集上训练不同的 ELM 心跳分类模型. 最后通过多数投票的方式, 票数最多的心跳类别即为最终集成的分类结果.

3 实验验证

本文中使用麻省理工心律失常公开数据集 (MIT-BIH arrhythmia dataset) 对所提出的方法进行验证.

3.1 数据集

MIT-BIH 心律失常数据库是研究心律失常分类算法广泛使用的数据库之一^[26]. 它包含 48 个 0.5 h 的双通道动态心电图记录, 其中的 23 份为比较常见




图 4 ELM 心跳分类结构

Fig.4 ELM heartbeat classification structure

的心律失常记录,而其余的 25 份为较少见但临床意义重大的心律失常记录^[27]. 这些记录来自于 BIH 心律失常实验室在 1975 年至 1979 年间研究的 47 名受试者,从波士顿贝斯以色列医院住院病人(约 60%)和门诊病人(约 40%)的混合人群中收集得到.

在通道一, 45 条记录来自改进的肢体导联 II(Modified limb lead II, MLII), 其余 3 条记录来自改进的胸前导联 V5(Modified precordial lead V5). 在通道二, 40 条记录来自导联 V1, 4 条来自导联 V2, 1 条来自 V4, 2 条来自 V5, 还有一条来自 MLII. 本文中, 我们使用通道一的数据, 因为通道一的数据都来自于导联 MLII.

这些记录被带通滤波到 0.1 ~ 100 Hz 的频率范围, 然后将带通滤波后的信号数字化到 360 Hz. 所有的 ECG 信号使用两个中值滤波器来消除基线漂移, 分别是 0.2 s 宽度的中值滤波器和 0.6 s 宽度的中值滤波器.

MIT-BIH 数据库中提供了大概的 R 峰基准点的位置. 我们使用提供的基准点位置, 然后对其进行了手工纠正. 接下来, 根据基准点的位置, 前 90 个点和后 144 个点总共 234 个点组成的片段, 作为一个心跳片段. 在数据库中心跳数据的真实标签是由两个心脏病专家手工标注得到, 因此我们使用提供的标签作为心跳的真实标签. 在我们的实验中, 所有 48 条记录被使用, 总共将心跳信号分为 16 类.

表 1 详细的描述了数据集的情况. 我们的实验中, 数据集的划分和文献 [9] 中保持一致. 具体来说, 将 N 类样本的 13%, L、R、A、V、P 类各类样

本的 40% 以及其余的心律失常类样本的 50% 从各自的样本中随机选择出来, 然后组成了训练样本, 剩余的样本组成了测试样本.

表 1 MIT-BIH 数据集的详细描述和划分

Table 1 Detailed description and division of the MIT-BIH dataset

Heartbeat type (abbreviation)	Annotation	Total number of samples	Number of training samples	Number of testing samples
Normal beat (NOR)	N	75023	9753	65270
Left bundle branch block (LBBB)	L	8072	3229	4843
Right bundle branch block (RBBB)	R	7255	2902	4353
Atrial premature contraction (APC)	A	2546	1018	1528
Premature ventricular contraction (PVC)	V	7129	2852	4277
Paced beat (PACE)	/	7026	2810	4216
Aberrated atrial premature beat (AP)	a	150	75	75
Ventricular flutter wave (VF)	!	472	236	236
Fusion of ventricular and normal beat (VFN)	F	802	401	401
Blocked atrial premature beat (BAP)	x	193	96	97
Nodal (junctional) escape beat (NE)	j	229	114	115
Fusion of paced and normal beat (FPN)	f	982	491	491
Ventricular escape beat (VE)	E	106	53	53
Nodal (junctional) premature beat (NP)	J	83	42	41
Atrial escape beat (AE)	e	16	8	8
Unclassifiable beat (UN)	Q	33	16	17
Total	16	110117	24096	86021

3.2 性能指标

为了评价心跳分类方法的性能, 我们使用以下三个指标, 分别为: 准确率 (Accuracy), 召回率 (Recall) 和精确率 (Precision). 其中, 准确率反映了模型预测正确的样本占有所有样本的比例, 召回率反映了在真实类为正类的样本中, 模型识别为正类样本所占的比例, 精确率反映了在模型识别为正类的所有样本中, 真实类也为正类样本所占的比例. 它们的计算方法如下:

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

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \times 100\% \quad (9)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \times 100\% \quad (10)$$

其中, TP、TN、FN 和 FP 分别为真阳性数 (True positive)、真阴性数 (True negative)、假阴性数 (False negative) 和假阳性数 (False positive).

3.3 实验结果

实验统一采用五折交叉验证的方式进行模型效果评估. 抽样的方式选择分层抽样, 也就是说, 在训练集中, 我们对于每一类心跳分别将其平均分为五份, 将每一类中的每一份样本进行组合, 形成五份样本子集. 轮流选取其中的四份作为训练集, 一份作为验证集. 重复训练及验证模型五次, 并将五次结果的平均准确率作为模型选择的评价标准.

表 2 中给出了每一个心跳类别的召回率和精确率. 大部分类别呈现出了满意的分类性能, 除了类别 a、F、e 和 Q. 表 3 给出了分类结果的混淆矩阵 (Confusion matrix), 从中我们可以观察到具体的分类情况. 具体地, 在真实类别为 a 类的所有样本中, 26 个被误分, 主要为 11 个样本被误分为 N, 4 个被误分为 A, 还有 7 个被误分为 V, 其原因是类别 a 与其他 3 个误分类别的形态学差异并不明显; 82 个 F 类样本被误分, 主要为 54 个 F 类样本被误分为 N 类, 27 个被误分为 V 类, 原因在于 MIT-BIH 数据集编号为 213 的记录中, F 类样本和 N、V 类样本具有很强的形态学相似性, 这就导致 F 类很容易被错误地识别为 N 和 V 类; 在所有 8 个 e 类样本中仅仅分对了 1 例, 而其他都被误分为 N 类, 这也是归因于在 MIT-BIH 数据集编号为 223 的记录中, e 类心跳信号与 N 类的形态学特征并没有明显的区别; Q 类的心跳信号表现为无规则地而且幅值变化很大的震荡, 心血管专家将这

类样本标注为未分类样本, 因此如何减少这类样本的信号变形和损失是关键, 但这不在本文研究的范围内.

表 2 每类心跳的召回率和精确率
Table 2 Recall and precision for each heartbeat class

Heartbeat type	Number of test samples	Recall/%	Precision/%
N	65270	99.58	99.43
L	4843	99.71	99.67
R	4353	99.61	99.34
A	1528	86.45	94.90
V	4277	97.80	95.57
/	4216	99.69	99.41
a	75	65.33	92.45
!	236	93.64	92.47
F	401	79.55	87.40
x	97	86.60	94.38
j	115	87.83	71.13
f	491	91.65	96.98
E	53	94.34	98.04
J	41	90.24	97.37
e	8	12.50	100.00
Q	17	5.88	50.00
Total	86021	99.02	99.02

表 4 展示了所提方法与其他方法的比较结果. 基于融合特征的 ELM 算法在单导联的准确率为 98.81%, 比文献 [9] 中方法得到的 98.72% 准确率更高. 而且, 基于融合特征的分类方法其效果要好于单独用手工特征或深度特征的方法. 另外, 基于 Bagging 集成的 ELM 分类方法进一步提升了分类性能, 达到了 99.02% 的最高准确率.

4 结论

本文提出了一种基于手工特征和深度特征融合的集成超限学习机心跳分类方法. 手工提取的特征包括 RR 间期特征和离散小波系数特征, 分别反映了心跳信号的时域特性和时频特性. 同时设计了针对心跳信号的 1D CNN 结构, 对心跳信号的深度特征进行自动提取. ELM 模型融合上述特征并进行心跳分类. 由于 ELM 初始参数随机生成, 这种方式会导致 ELM 出现分类性能不稳定的现象, 因此, 针对上述问题, 本文采用基于 Bagging 策略的多 ELM 集成方法. 实验结果表明, 将深度特征与手工特征融合能更全面地表征心跳信号,

表3 混淆矩阵

Table 3 Confusion matrix

		Predict labels															
		N	L	R	A	V	/	a	!	F	x	j	f	E	J	e	Q
True labels	N	64996	9	3	58	126	1	0	8	28	4	32	4	0	0	0	1
	L	6	4829	0	0	7	0	0	0	0	0	0	0	1	0	0	0
	R	8	0	4336	6	2	0	1	0	0	0	0	0	0	0	0	0
	A	169	1	20	1321	9	0	0	1	0	0	6	1	0	0	0	0
	V	62	4	1	2	4183	0	1	5	18	0	0	1	0	0	0	0
	/	5	0	0	0	1	4203	0	0	0	0	1	6	0	0	0	0
	a	11	2	0	4	7	0	49	2	0	0	0	0	0	0	0	0
	!	8	0	0	0	5	0	1	221	0	1	0	0	0	0	0	0
	F	54	0	1	0	27	0	0	0	319	0	0	0	0	0	0	0
	x	4	0	0	1	4	0	1	2	0	84	1	0	0	0	0	0
	j	12	0	1	0	0	0	0	0	0	0	101	0	0	1	0	0
	f	16	0	0	0	1	24	0	0	0	0	0	450	0	0	0	0
	E	1	0	0	0	2	0	0	0	0	0	0	0	50	0	0	0
	J	1	0	2	0	0	0	0	0	0	0	1	0	0	37	0	0
	e	7	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0
	Q	10	0	1	0	3	0	0	0	0	0	0	2	0	0	0	1

表4 提出的方法与其他方法的比较结果

Table 4 Comparison results of the proposed approach with other approaches

Reference	Features + Classifier	Accuracy/ %
Manual features only	DWT, RR + ELM (Single)	98.28
Deep feature only	1D CNN	98.50
Feature fusion (Without ensemble)	DWT, RR, 1D Convolution + ELM (Single)	98.81
Ye ^[9]	ICA, Wavelet, RR + SVM (One-against-one)	98.72
Our proposed approach	DWT, RR, 1D Convolution + ELM (Bagging ensemble)	99.02

并得到更好的分类结果。此外，基于 Bagging 策略的 ELM 集成方法可进一步提升心跳分类性能。未来工作将基于其他公开的心律失常数据集，对所提出的方法加以改进。同时，将所提方法应用到临床实践中。

参 考 文 献

[1] Thaler M S. The Only EKG Book You'll Ever Need. 9th Ed. Philadelphia, PA: Lippincott Williams & Wilkins, 2017[2] Gawlowska J, Wranicz J K, Norman J. "Jeff" Holter (1914—1983). *Cardiol J*, 2009, 16(4): 386

[2] Chazal P d, Reilly R B. A patient-adapting heartbeat classifier using ECG morphology and heartbeat interval features. *IEEE Trans Biomed Eng*, 2006, 53(12): 2535

[3] Mondéjar-Guerra V, Novo J, Rouco J, et al. Heartbeat classification fusing temporal and morphological information of ECGs via ensemble of classifiers. *Biomed Signal Process Control*, 2019, 47: 41

[4] Chazal P d, O'Dwyer M, Reilly R B. Automatic classification of heartbeats using ECG morphology and heartbeat interval features. *IEEE Trans Biomed Eng*, 2004, 51(7): 1196

[5] Tuncer T, Dogan S, Plawiak P, et al. Automated arrhythmia detection using novel hexadecimal local pattern and multilevel wavelet transform with ECG signals. *Knowl Based Syst*, 2019, 186: 104923

[6] Sahoo S, Kanungo B, Behera S, et al. Multiresolution wavelet transform based feature extraction and ECG classification to detect cardiac abnormalities. *Measurement*, 2017, 108: 55

[7] Afkhami R G, Azarnia G, Tinati M A. Cardiac arrhythmia classification using statistical and mixture modeling features of ECG signals. *Pattern Recognit Lett*, 2016, 70: 45

[8] Marinho L B, Nascimento N M M, Souza J W M, et al. A novel electrocardiogram feature extraction approach for cardiac arrhythmia classification. *Future Gener Comput Syst*, 2019, 97: 564

[9] Ye C, Vijaya Kumar B V K, Coimbra M T. Heartbeat classification using morphological and dynamic features of ECG signals. *IEEE Trans Biomed Eng*, 2012, 59(10): 2930

[10] Castillo O, Melin P, Ramirez E, et al. Hybrid intelligent system for cardiac arrhythmia classification with Fuzzy K-Nearest Neighbors and neural networks combined with a fuzzy system. *Expert Syst*

- Appl*, 2012, 39(3): 2947
- [11] Girshick R. Fast R-CNN // 2015 *IEEE International Conference on Computer Vision (ICCV)*. Santiago, 2015: 1440
- [12] Huang G, Liu Z, Van Der Maaten L, et al. Densely connected convolutional networks // 2017 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Honolulu, 2017: 2261
- [13] He K M, Zhang X Y, Ren S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition. *IEEE Trans Pattern Anal Mach Intell*, 2015, 37(9): 1904
- [14] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions // 2015 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Boston, 2015: 1
- [15] Schroff F, Kalenichenko D, Philbin J. FaceNet: A unified embedding for face recognition and clustering // 2015 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Boston, 2015: 815
- [16] Ding C X, Tao D C. Trunk-branch ensemble convolutional neural networks for video-based face recognition. *IEEE Trans Pattern Anal Mach Intell*, 2018, 40(4): 1002
- [17] He R, Wu X, Sun Z N, et al. Wasserstein CNN: Learning invariant features for NIR-VIS face recognition. *IEEE Trans Pattern Anal Mach Intell*, 2019, 41(7): 1761
- [18] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation. *IEEE Trans Pattern Anal Mach Intell*, 2017, 39(4): 640
- [19] LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition. *Proc IEEE*, 1998, 86(11): 2278
- [20] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: Theory and applications. *Neurocomputing*, 2006, 70(1-3): 489
- [21] Huang G B, Chen L, Siew C K. Universal approximation using incremental constructive feedforward networks with random hidden nodes. *IEEE Trans Neural Netw*, 2006, 17(4): 879
- [22] Anthimopoulos M, Christodoulidis S, Ebner L, et al. Lung pattern classification for interstitial lung diseases using a deep convolutional neural network. *IEEE Trans Med Imaging*, 2016, 35(5): 1207
- [23] Li J Y, Zhao Y K, Xue Z E, et al. A survey of model compression for deep neural networks. *Chin J Eng*, 2019, 41(10): 1229
(李江昀, 赵义凯, 薛卓尔, 等. 深度神经网络模型压缩综述. 工程科学学报, 2019, 41(10): 1229)
- [24] Ji S W, Xu W, Yang M, et al. 3D convolutional neural networks for human action recognition. *IEEE Trans Pattern Anal Mach Intell*, 2013, 35(1): 221
- [25] Bartlett P L. The sample complexity of pattern classification with neural networks: The size of the weights is more important than the size of the network. *IEEE Trans Inf Theory*, 1998, 44(2): 525
- [26] PhysioNet. MIT-BIH Arrhythmias Database [J/OL]. *PhysioNet Online* (2020-04-15)[2021-01-12] <https://physionet.org/files/mitdb/1.0.0>
- [27] Moody G B, Mark R G. The impact of the mit-bih arrhythmia database. *IEEE Eng Med Biol Mag*, 2001, 20(3): 45