

DOI:10.3969/j.issn.1005-202X.2023.11.013

医学信号处理与医学仪器

基于马尔可夫转移场与改进 MobileNetV2 的心律失常分类方法

冀常鹏, 邓伟, 代巍

辽宁工程技术大学电子与信息工程学院, 辽宁 葫芦岛 125105

【摘要】心律失常自动分类对心血管疾病的预防尤为重要,本研究提出一种基于马尔可夫转移场(MTF)和改进 MobileNetV2 网络的心律失常图像分类方法。首先将原始心电(ECG)信号进行预处理和数据增强,并通过 MTF 将处理后的 ECG 片段转变为具有时间关联性的二维图像。其次在 MobileNetV2 网络的模块中融入高效通道注意力。将正常心拍、左束支传导阻滞、右束支传导阻滞和起搏心拍4种类型的 ECG 信号通过改进 MobileNetV2 网络进行分类。结果表明改进 MobileNetV2 模型复杂度仅略高于原始 MobileNetV2,在心律失常分类准确率上,比原始 MobileNetV2 网络提高 0.89%,达到 99.71%,实现了对4种不同类型的 ECG 信号的有效分类。

【关键词】心律失常;马尔可夫转移场;MobileNetV2;二维图像;注意力机制

【中图分类号】R318;TP391

【文献标志码】A

【文章编号】1005-202X(2023)11-1395-07

Markov transfer field combined with modified MobileNetV2 for arrhythmia classification

Ji Changpeng, Deng Wei, Dai Wei

School of Electronic and Information Engineering, Liaoning Technical University, Huludao 125105, China

Abstract: The automatic arrhythmia classification is critical for cardiovascular disease prevention. An approach for arrhythmia classification based on Markov transfer field (MTF) and modified MobileNetV2 network is presented. After preprocessing and data enhancement for the original electrocardiogram (ECG) signals, MTF maps the processed ECG segments into two-dimensional images with temporal correlation, and then a modified MobileNetV2 network which incorporates with efficient channel attention classifies the ECG signals of 4 types: normal beat, left bundle-branch block, right bundle-branch block, and paced beat. The results show that the modified MobileNetV2 is slightly more complex than the original MobileNetV2, and it has a classification accuracy of 99.71%, which is 0.89% higher than the original MobileNetV2, demonstrating that the proposed approach can achieve the effective arrhythmia classification.

Keywords: cardiac arrhythmia; Markov transfer field; MobileNetV2; two-dimensional image; attention mechanism

前言

随着年龄的增长,心血管系统凋亡的心肌细胞随之增加,传导组织的结构和功能也会发生变化,心血管疾病患病率不断增加。大量的报告显示我国心血管疾病的发病率和致死率都位于首位^[1]。心律失常是一组心跳节拍过慢或过快的情况,可以是有规律的,也可以是无规律的。先天遗传或后天病理所引起的心脏传导系统变化是导致心律失常的主要原因^[2]。心律失常的诊断主要是通过心电图(ECG)的特征进行辨别,通过 ECG 信号中的一些特征自动检

测心律失常是心血管疾病自动诊断的重要任务。在临床诊断中,主要是依靠熟练的临床医生经验对心律失常的类型进行辨别,该方法需要医生具备很强的专业能力和丰富的经验,而且存在分辨时间长和效率低等问题^[3-4]。所以,提出一种能迅速识别心律失常且准确率高的分类模型十分必要。文献[5]将 ECG 信号进行切片并进行小波滤波处理,然后将数据馈送到概率神经网络进行分类。文献[6]将 ECG 信号通过离散小波变化进行高频噪声去除和消除基线漂移,并利用随机森林算法进行分类。文献[7]利用一种聚类分析方法分析心电信号用来诊断心律失常。

传统上对于心律失常的分类,可以分为两个步骤,首先对 ECG 信号的特征进行提取,再对所提取的特征进行分类。ECG 中两个 R 峰之间称为 R-R 区间,因为在 ECG 中的 QRS 波具有显著形态,因此许多研

【收稿日期】2023-06-10

【基金项目】辽宁省教育厅基本科研项目(LJKMZ20220677)

【作者简介】冀常鹏,教授,研究方向:计算机通信与网络、工程机械控制、微弱信号处理与辨识,E-mail: ccp@lntu.edu.cn

究都是基于这一区间内进行的。文献[8]提出一种基于形态学和动力学特征相结合的新分类方法,利用小波变换和独立成分分析(ICA)分别应用于R-R区间以提取形态特征,再通过支持向量机(SVM)进行分类。文献[9]同时使用主成分分析、线性判别分析和ICA降低数据维数,同时采用SVM和两种神经网络分类器来实现心电信号的自动分类。

已有的方法对ECG信号进行研究通常都是基于R-R区间,需要确定心拍的位置,多数的研究都使用R峰的位置作为参考点进行心拍划分。对于R峰位置的确定方式有两种:一种是根据数据库中专家对R峰的标注,另一种是通过现有的R峰检测算法计算。例如Pan-Tompkins算法^[10],其定位心拍可以达到99.3%的准确率,但由于一些心律失常的心拍会存在峰值很接近的情况,而且此类算法允许识别的心拍和真实心拍存在误差,所以得到的数据与真实数据之间会有差异,从而导致对相同数据进行心拍分割,得到的心拍形态不同^[11]。由专家进行心拍的标定,很难做到所有的心拍都可以快速且无遗漏地标注。所以,在实际研究中上述两种方法都有各自的弊端。

深度学习在模式识别应用中表现突出,可以自适应地直接从数据中自动学习复杂且具有代表性的特征,降低对手动特征提取的过度依赖^[12]。文献[13]将ECG信号划分为R-R区间,利用卷积神经网络(CNN)和长短期记忆(LSTM)方法相结合对6类心律失常信号进行分类,通过CNN对ECG信号的节拍进行特征提取,LSTM对时间信息进行提取,改变了只对QRS波形特征的提取方式。文献[14]将ECG信号转化为二维图像,并通过具有倒残差结构的轻量神经网络进行分类,在减少网络参数的同时,保证分类准确率。文献[15]利用双树复小波变换(DTCWT)方法对移位不变性的心电信号进行重构并提取显著特征,之后通过带有注意力机制的神经网络进行分类,通过引入注意力机制增强对重要特征的提取能力,从而达到更好的分类效果。文献[16]提出基于二维图像和融合注意力机制的神经网络分类方法,将ECG信号划分为2.5 s的片段并通过格拉姆角和场将其转化二维图像,通过带有卷积注意力模块(CBAM)的神经网络进行分类。取代传统方法对心拍的定位,并将数据映射到二维。文献[17]通过将ECG信号进行切片,之后将信号通过短时傅里叶变化为频谱图在卷积神经网络中进行分类。仅仅对时间序列进行特征提取一般不能全面地反应ECG信号在其它方面的特征,如频率和时间的关系。频谱图只能映射出ECG信号的在频率域的特征,从而忽略了信号在时间上的特征。

针对以上问题,本研究提出了利用马尔可夫转移场(Markov Transfer Field, MTF)将一维ECG信号转化为二维图像,通过改进MobileNetV2模型(ECA-MobileNetV2)对心电信号进行分类。避免了对ECG信号手动提取特征的依赖,同时利用MTF对时间的依赖特征性及频率特性以及注意力机制对重要特征的提取,从而实现了心律失常更好的分类。

1 本文算法

1.1 MTF

MTF是一种将时间序列映射为二维矩阵的方法,首先将 n 个采样点的原始ECG信号定义为 $X=\{x_1, x_2, \dots, x_n\}$,再将信号的值离散化分为 Q 等份,每个 x_i 都对应着一个 $q_j (j \in [1, Q])$,通过马尔可夫链计算原理信号点在 q_j 之间的转移概率,得到一个 $Q \times Q$ 的矩阵 W 。 w_{ij} 是 q_j 中的元素跟随 q_i 中元素的概率。矩阵 W 如公式(1)所示:

$$W = \begin{bmatrix} w_{11} & \cdots & w_{1Q} \\ \vdots & & \vdots \\ w_{Q1} & \cdots & w_{QQ} \end{bmatrix} \quad (1)$$

为了全面显示时间序列的细节特征,拓展为MTF(M),如式(2)所示:

$$M = \begin{bmatrix} m_{ij|P(x_i \in q_i | x_i \in q_j)} & \cdots & m_{ij|P(x_i \in q_i | x_i \in q_j)} \\ m_{ij|P(x_2 \in q_i | x_1 \in q_j)} & \cdots & m_{ij|P(x_2 \in q_i | x_1 \in q_j)} \\ \vdots & \ddots & \vdots \\ m_{ij|P(x_n \in q_i | x_1 \in q_j)} & \cdots & m_{ij|P(x_n \in q_i | x_1 \in q_j)} \end{bmatrix} \quad (2)$$

其中, m_{ij} 是 q_j 中的元素被 q_i 中的元素跟随的概率。

对于长度为 n 的ECG信号序列,得到的马尔可夫矩阵大小为 $n \times n$ 。当 n 过大时,卷积神经网络的计算量会增加,所以采用了分段聚合近似(Piecewise Aggregate Approximation, PAA)方法对原始ECG信号进行降低维度处理。

比较于其它方法对特征的单一提取,MTF对特征的提取还与时间相关,对信号变化信息更敏感^[18];同时能够很好地保留了一维信号的时间依赖性及频率特征;不同的转移概率导致图像像素点有差异,将其作为输入可以更好地发挥卷积神经网络对图像分类的优势。

1.2 改进的MobileNetV2模型

1.2.1 MobileNetV2 模型 MobileNetV2是在MobileNetV1的基础上进行改进的轻量化网络模型结构并构建了比V1版本更深层的模型结构,同时具有更高的准确度^[19]。主要由深度可分离卷积(Depth Separable Convolution)和倒残差线性瓶颈结构(Inverse Residual Linear Bottleneck Structure)组成。在深度可分离卷积中,先利用深度卷积采集输入特

征通道上的信息得到中间输出,再利用逐点卷积完成特征信息的最终输出,这一过程的参数量远小于传统卷积,使网络更加轻量化。

核心结构采用倒残差结构,以增强逐通道卷积的特征提取能力。由于激活函数 ReLu 的特性会造成特征丢失,所以在倒残差结构的最后一层使用线性激活函数来代替常规的 ReLu 激活函数。MobileNetV2 的基本模块如图 1 所示。

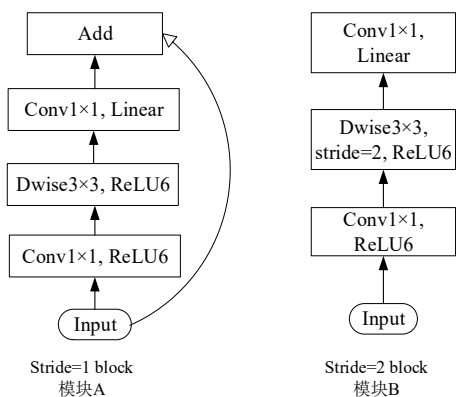


图 1 MobileNetV2 的基本模块
Figure 1 Basic modules of MobileNetV2

当卷积的步距为 1 时使用模块 A,在模块中输入特征与输出特征维度相同,在模块中同样存在和残差模块相同的捷径分支;当卷积的步距为 2 时,网络使用模块 B,减少网络参数。

1.2.2 融合模型设计 ECG 信号大量的信息集中在 QRS 波形,为了更好地提取 ECG 信号中的重要信息,采用高效通道注意力 (Efficient Channel Attention, ECA) 增强对重要特征的提取^[20]。ECA 机制避免了降维,并以高效的方式捕捉跨通道交互。在不降维的情况下通过全局平均池化 (Global Average Pooling, GAP) 操作对每个通道中的特征图进行压缩,并通过考虑每个通道及其 k 条邻近卷积通道来捕获局部跨通道交互。ECA 结构如图 2 所示。

首先将输入的特征图进行 GAP 操作得到聚合特征,然后通过卷积核大小为 k 的一维卷积来进行局部跨通道信息融合。其中卷积核大小 k 代表了局部的跨通道信息融合的覆盖率, k 与通道维数 C 是成非线性比例,通过非线性映射,高维通道的相互作用距离较长,而低维通道相互作用距离较短,关系如公式 (3) 所示:

$$C = \phi(k) = 2^{(Ak - d)} \tag{3}$$




图 2 ECA 结构
Figure 2 Structure of efficient channel attention

给定通道维数 C ,卷积核大小 k 便可以自适应确定,具体如公式 (4) 所示:

$$k = \psi(C) = \left\lceil \frac{\log(C)}{\lambda} + \frac{d}{\lambda} \right\rceil_{\text{odd}} \tag{4}$$

其中, λ 、 d 是调节参数; $\lceil b \rceil$ 表示 b 最近的奇数。

将 ECA 模块插入到 MobileNetV2 网络的主要模块中,通过增加较少的参数,达到对所需要特征赋予更多权重的目的。改进 MobileNetV2 网络如图 3 所示。整体的心律失常分类模型如图 4 所示。将输入的 ECG 信号截取 5 s 的片段,并通过 PPA 进行聚合,根据 MIT-BIH 数据库的专家注释选取数据^[21],并分为 4 类一维 ECG 信号。依据 MTF 将选取的 ECG 信号映射到二维图像。将马尔可夫特征图像输入到改进 MobileNetV2 网络中,通过神经网络进行特征提取,最后将 ECG 信号分类。

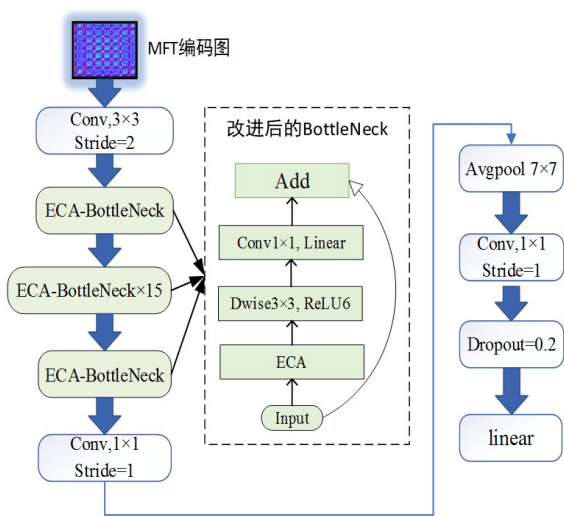


图 3 改进的 MobileNetV2 网络
Figure 3 Modified MobileNetV2




图 4 心律失常分类整体流程图
Figure 4 Overall flowchart of arrhythmia classification

2 仿真验证

2.1 实验数据来源

心律失常实验数据来自于麻省理工学院提供的 MIT-BIH 数据库。它具有高度的异质性,其中记录的患者年龄、性别、国籍不尽相同,涵盖的范围广,对应心律失常的类别也很多,所以该数据库被广泛用于研究。每条 ECG 记录时长约为 30 min,采样频率统一为 360 Hz,并且至少有两位心脏病学家对每一个心拍做了注释。MIT-BIH 数据库中注释的主要心拍类型如表 1 所示。

表 1 MIT-BIH 数据库主要心拍类型
Table 1 Main heart beat types in MIT-BIH database

标识符	心拍类型
Normal(N)	正常心拍
LBBB(L)	左束支传导阻滞
RBBB(R)	右束支传导阻滞
APB(A)	房性早搏
ABERR(a)	房性早搏伴差异性传导
NPC(J)	结性早搏
SVPB(S)	室上性早搏
PVC(V)	室性早搏
FUSION(F)	室性融合拍
AESC(e)	房性逸搏
NESC(j)	结性逸搏
VESC(E)	室性逸搏
PACE(/)	起搏心拍

ECG 信号记录包含两种不同类型的通道数据,本研究所选的通道为Ⅱ导联(MLII),此外数据库中还有 V1、V2、V4 或 V5 为第二通道。不同的通道对应的 ECG 形状和特征不同。

2.2 数据预处理

选取的 4 类心拍分别为正常心拍(Normal, N)、左束支传导阻滞(Left Bundle Branch Block, LBBB)、右束支传导阻滞(Right Bundle Branch Block, RBBB)、起搏心拍(Paced Beat, PACE)。将原始的 ECG 信号进行切片,每个片段长为 5 s,采样频率为原始采样频率 360 Hz,所得片段长度为 1 800 个采样点。此方式下一个样本中会存在不同心拍类型的情况。为了解决这个问题,依据 MIT-BIH 心律失常数据库中心脏专家对每个峰值的注释,如果该段心拍中存在其它类型的心拍,则去掉该片段。由于所选取的 4 类心拍之间数据不平衡,所以通过 SMOTE 算法解决类不平衡问题^[22]。

表 2 列出了 MIT-BIH 心律失常数据库中所使用数据的相关信息。对于 Normal、LBBB、RBBB 和 PACE,后 3 类的 ECG 信号训练集的数量为 720 张、验证集的数量为 240 张,测试集数量为 240 张。Normal 数据集的训练集数量为 900 张、验证集数量为 300 张,测试集数量为 300 张。

2.3 ECG 信号转化为二维图像

将预处理后的样本,通过 MTF 进行特征提取,并将 ECG 时域信号转换为二维图像,图像的像素为 328×328。所选取的样本编号为 105、111、124 和 217。图 5 为预处理过的 ECG 信号转化为二维图像,每个

表 2 所选数据编号及数量
Table 2 Selected data number and quantity

心拍类型	心拍编号	训练集数量/张	验证集数量/张	测试集数量/张
Normal	100、105、215	900	300	300
LBBB	109、111、214	720	240	240
RBBB	118、124、212	720	240	240
PACE	107、217	720	240	240

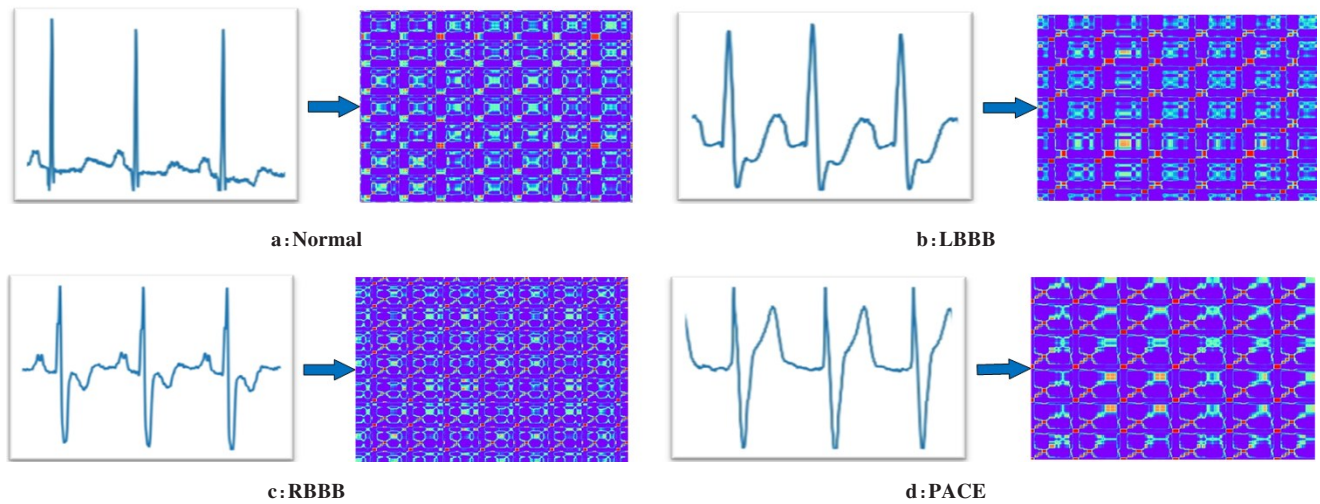


图 5 4 类心电信号二维图像转换图
Figure 5 Mapping 4 types of ECG signals into two-dimensional image

比例分为 6:2:2。数据经过中心裁剪后为 224×224 大小,随机将数据送入设计好的训练模型进行特征提取,最后进行分类。本文模型采用 Adam 优化器,学习率为 0.000 5, batch-size 为 64。

3 实验结果与分析

3.1 评价指标

选取损失函数(loss)、准确率(Accuracy, Acc)、召回率(Recall, Re)、精确率(Precision, Pr)和 F1 分数对分类结果进行评估和分析,计算公式如式(5)~(9)所示:

$$\text{loss} = -\sum_{i=1}^n y_i \ln f_i(x) \tag{5}$$

其中, x 为输入数据, n 为选择分类的类别数, y_i 为第 i 种类别对应的真实标签, $f_i()$ 为模型输出值。

$$\text{Acc} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \times 100\% \tag{6}$$

$$\text{Re} = \frac{\text{TP}}{\text{TP} + \text{FN}} \times 100\% \tag{7}$$

$$\text{Pr} = \frac{\text{TP}}{\text{TP} + \text{FP}} \times 100\% \tag{8}$$

$$\text{F1} = 2 \times \frac{\text{Re} \times \text{Pr}}{\text{Re} + \text{Pr}} \times 100\% \tag{9}$$

小图左边为 ECG 切片信号,右边为对应的 MTF 变化后的二维图像。

2.4 改进 MobileNetV2 网络训练

采用改进 MobileNetV2 网络作为 ECG 心律失常特征提取器。利用 MTF 将一维时序信号的信号映射到马尔可夫转移矩阵,将矩阵的不同值用像素点表示为特征图,将 5 100 张特征图作为数据集。随机按

其中, TP(True Positive)为当前该心拍被预测正确的数量;FP(False Positive)为不属于当前心拍类型而被预测当前心拍的个数;FN(False Negative)为属于当前心拍类型而被错误预测为其它心拍的个数;TN(True Negative)为其它心拍被正确分为其它心拍的个数。

3.2 结果分析

将改进的 MobileNetV2 与其它经典网络 MobileNetV2、ShuffleNetV2-2.0X、EfficientNet-b0 同时对本文数据集进行测试,并将不同评价指标进行对比。不同网络的准确率和损失值分别如图 6 和图 7 所示。

从图 6 可以看出,改进 MobileNetV2 模型准确率高于其他 3 种模型,并且模型具有更快的收敛速度,说明其泛化能力更强。从图 7 可以看出,相较于其它模型,改进 MobileNetV2 模型的损失值更低,模型有更好的稳定性。

3.3 不同模型的评价指标对比

如表 3 所示,改进 MobileNetV2 模型在准确率、召回率、精确率和 F1 分数均为最高。改进 MobileNetV2 模型准确率为 99.71%,相比于 MobileNetV2、EfficientNet-b0 和 ShuffleNetV2-2.0X 分别高出 0.89%、0.88% 和 3.04%。相较于原始的 MobileNetV2 模型,改进后的 MobileNetV2,在召回




图 6 4 种不同模型的准确率
Figure 6 Accuracy of 4 different models




图 7 4 种不同模型的损失值
Figure 7 Loss values for 4 different models

率、精确率和 F1 分数分别提高了 0.89%、0.88% 和 0.89%。表明改进网络的有效性,可以将其应用于心律失常分类。

表 3 4 种模型性能评价指标对比(%)
Table 3 Performance comparison among 4 models (%)

模型	准确率	召回率	精确率	F1 分数
改进 MobileNetV2	99.71	99.72	99.71	99.72
MobileNetV2	98.82	98.83	98.83	98.83
EfficientNet-b0	98.83	98.85	98.84	98.83
ShuffleNetV2-2.0X	96.67	96.89	96.77	96.82

对比 4 类模型的网络参数量、浮点运算数和权值文件大小,分析网络的复杂度(表 4)。改进 MobileNetV2 模型在本文数据集集中的参数量为 3.50 M,低于模型 EfficientNet-b0 的参数量(5.29 M)和模型 ShuffleNetV2-2.0X 的参数量(7.40 M);同时浮点运算数为 327.55 M,权值文件大小为 9.17 Mb,略高于 MobileNetV2,低于 EfficientNet-b0 和 ShuffleNetV2-2.0X。综合表中的 3 类指标,改进模型复杂度较低。

表 4 4 种模型复杂度比较
Table 4 Complexity comparison among 4 models

模型	参数量/M	浮点运算数/M	权值文件大小/Mb
改进 MobileNetV2	3.50	327.55	9.17
MobileNetV2	3.50	327.49	9.16
EfficientNet-b0	5.29	412.83	16.35
ShuffleNetV2-2.0X	7.40	598.23	21.66

图 8 为改进的模型在测试集上所得到的混淆矩阵。横轴代表真实值,纵轴代表网络预测值。对角线上的值为该类型样本预测正确的个数。在图中可以看出,正常心拍和 LBBB 之间存在相互识别错误的情况。




图 8 分类结果的混淆矩阵
Figure 8 Confusion matrix of classification results

将改进 MobileNetV2 模型与之前的 ECG 心律失常分类模型进行对比^[23-27]。文献[16]提出将时间序列 ECG 信号通过格拉姆角和场转化为二维图像,并通过带有卷积注意力模块的残差网络对 5 类心电信号进行特征提取和分类,分类准确率为 99.23%。文献[25]提出利用最小二乘和支持向量机分类器(LS-SVM),并将 ECG 信号分为 3 类,准确率达到 95.82%。文献[26]提出一种基于 R-R 区间分类方法,利用 PCA 和动态时间扭曲(DTW)从所选择的 ECG 片段中提取特征,通过 SVM 进行特征提取,最终准确率为 97.80%。文献[27]将 ECG 信号进行切片并划分为 5 类,并且利用深度残差卷积网络(DCNN)进行特征提取和分类,最终达到 93.44% 的准确率。文献[28]通过将原始 ECG 信号进行切片,通过递归图(RP)的方法将其转化为二维图像,并通过卷积神经网络进行 4 类 ECG 信号的分类,其准确率为 98.36%。文献[29]将 ECG 信号划分为单个心拍和在 R-R 区间两种数据,并对数据进行去噪处理,最后通过密集连接卷积网络和双向长短期记忆网络的组合对 8 种心拍类型

进行分类处理,总体的分类准确率为92.75%。表5为本文模型与其它模型的分类指标对比。

表5 与其它文献对比(%)
Table 5 Comparison with other literatures (%)

模型	准确率	精确率	召回率
本文模型	99.71	99.71	99.72
文献[16]	99.23	99.13	98.29
文献[23]	95.81	94.64	89.82
文献[24]	97.80	93.76	88.83
文献[25]	95.59	-	95.20
文献[26]	98.21	96.89	96.40
文献[27]	99.44	99.32	95.89

4 结 语

本研究提出基于MTF和改进 MobileNetV2 相结合的心律失常分类方法。利用MTF将一维的ECG信号编码为二维图像,将其通过融合高效通道注意力的神经网络分类模型对心律失常类型进行分类。由于MTF对时间的依赖性,所以可以保留更多ECG信号在时间上的特征。此外,本研究是基于ECG信号的片段分类模型,对比传统基于R-R区间的方法避免了对QRS定位算法的依赖性。同时使用改进模型进行分类,在略微增加模型复杂度的前提下,提高了分类准确率。下一步,将该方法应用于更多类型的心律失常ECG信号,同时要在更多的数据库中进行验证。

【参考文献】

[1] 马丽媛,王增武,樊静,等.《中国心血管健康与疾病报告2021》概要[J]. 中国介入心脏病学杂志, 2022, 30(7): 481-496.
Ma LY, Wang ZW, Fan J, et al. Summary of the Chinese cardiovascular health and disease report 2021[J]. Chinese Journal of Interventional Cardiology, 2022, 30(7): 481-496.

[2] Oh SL, Ng Eddie YK, Tan RS, et al. Automated beat-wise arrhythmia diagnosis using modified U-Net on extended electrocardiographic recordings with heterogeneous arrhythmia types[J]. Comput Biol Med, 2019, 105: 92-101.

[3] Amine BS, Hanene S, Ramzi M, et al. ConvNet: 1D-convolutional neural networks for cardiac arrhythmia recognition using ECG signals[J]. Trait Signal, 2021, 38(6): 1737-1745.

[4] 谢娟英,刘然. 基于深度学习的目标检测算法研究进展[J]. 陕西师范大学学报(自然科学版), 2019, 47(5): 1-9.
Xie JY, Liu R. The study progress of object detection algorithms based on deep learning[J]. Journal of Shaanxi Normal University (Natural Science Edition), 2019, 47(5): 1-9.

[5] Gneccchi JA, Morfin R, Lorias Adriana D, et al. DSP-based arrhythmia classification using wavelet transform and probabilistic neural network[J]. Biomedical Signal Processing and Control, 2017, 32: 44-56.

[6] Guo LP, Zhuo X, Si S, et al. Arrhythmia classification based on wavelet

transformation and random forests[J]. Multimed Tools Appl, 2018, 77(17): 21905-21922.

[7] Yeh YC, Chiou CW, Lin HJ. Analyzing ECG for cardiac arrhythmia using cluster analysis[J]. Expert Syst Appl, 2012, 39(1): 1000-1010.

[8] Ye C, Kumar B, Coimbra MT. Heartbeat classification using morphological and dynamic features of ECG signals[J]. IEEE Trans Biomed Eng, 2012, 59(10): 2930-2941.

[9] Martis RJ, Acharya UR, Min LC. ECG beat classification using PCA, LDA, ICA and discrete wavelet transform[J]. Biomed Signal Proces, 2013, 8(5): 437-448.

[10] Pan J, Tompkins WJ. A real-time QRS detection algorithm[J]. IEEE Trans Biomed Eng, 1985, 32(3): 230-236.

[11] 叶思超,徐晨华,乔清理. 基于残差网络融合模型的心律失常分类研究[J]. 陕西师范大学学报(自然科学版), 2020, 48(6): 10-17.
Ye SC, Xu CH, Qiao QL. Arrhythmia classification of ECG fragments based on residual network model fusion[J]. Journal of Shaanxi Normal University (Natural Science Edition), 2020, 48(6): 10-17.

[12] 秦默然,李宙童,翟月英,等. 基于空洞卷积神经网络的心律失常分类算法[J]. 中国医学物理学杂志, 2023, 40(1): 87-94.
Qin MR, Li ZT, Zhai YY, et al. Arrhythmia detection algorithm based on dilated convolutional neural network[J]. Chinese Journal of Medical Physics, 2023, 40(1): 87-94.

[13] Obeidat YM, Alqudah AM. A hybrid lightweight 1D CNN-LSTM architecture for automated ECG beat-wise classification[J]. Trait Signal, 2021, 38(5): 1281-1291.

[14] Liu Y, Jin Y, Liu J, et al. Precise and efficient heartbeat classification using a novel lightweight-modified method[J]. Biomed Signal Proces Control, 2021, 68: 102771

[15] Mangathayaru N, Rani P. An attention based neural architecture for arrhythmia detection and classification from ECG signals[J]. Comput Mater Con, 2021, 69(2): 2425-2443.

[16] Ma K, Zhan CA, Yang F. Multi-classification of arrhythmias using ResNet with CBAM on CWGAN-GP augmented ECG Gramian angular summation field[J]. Biomed Signal Proces, 2022, 77: 103684.

[17] Huang JS, Chen BQ, Yao B, et al. ECG arrhythmia classification using STFT-based spectrogram and convolutional neural network[J]. IEEE Access, 2019, 7: 92871-92880.

[18] 曹洁,马佳林,黄黛麟,等. 一种基于多通道马尔可夫变迁场的故障诊断方法[J]. 吉林大学学报(工学版), 2022, 52(2): 491-496.
Cao J, Ma JL, Huang DL, et al. A fault diagnosis method based on multi Markov transition field[J]. Journal of Jilin University (Engineering Edition), 2022, 52(2): 491-496.

[19] Sandler M, Howard A, Zhu M, et al. MobileNetV2: inverted residuals and linear bottlenecks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2018: 4510-4520.

[20] Wang Q, Wu B, Zhu P, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2020: 11531-11539.

[21] Moody GB, Mark RG. The impact of the MIT-BIH arrhythmia database[J]. IEEE Eng Med Biol Mag, 2002, 20(3): 45-50.

[22] Chawla NV, Bowyer KW, Hall LO, et al. SMOTE: synthetic minority over-sampling technique[J]. J Artif Intell Res, 2002, 16: 321-357.

[23] Dutta S, Chatterjee A, Munshi S. Correlation technique and least square support vector machine combine for frequency domain based ECG beat classification[J]. Med Eng Phys, 2010, 32(10): 1161-1169.

[24] 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.

[25] Kachuee M, Fazeli S, Sarrafzadeh M. ECG heartbeat classification: a deep transferable representation[C]//2018 IEEE International Conference on Healthcare Informatics. IEEE, 2018: 443-444.

[26] Mathunjwa M, Lin YT, Lin CH, et al. ECG recurrence plot-based arrhythmia classification using two-dimensional deep residual CNN features[J]. Sensors (Basel), 2022, 22(4): 853-879.

[27] Gan Y, Shi JC, He WM, et al. Parallel classification model of arrhythmia based on DenseNet-BiLSTM[J]. Biocybern Biomed Eng, 2021, 41(4): 1548-1560.

(编辑:薛泽玲)