

基于 ResNet-LSTM 的心电信号特征点 检测优化算法研究*

苏鹏¹ 王书涵¹ 潘国新² 张中钰¹ 王培利³

(1. 北京信息科技大学机电工程学院 北京 100192; 2. 国家康复辅具研究中心, 北京市老年功能障碍
康复辅助技术重点实验室, 民政部神经功能信息与康复工程重点实验室 北京 100176;
3. 中国中医科学院西苑医院国家中医心血管病医学研究中心 北京 100091)

摘要: 心电信号特征点的精确检测对医疗康复辅助设备、心脏监护系统及心脏病研究至关重要。针对传统方法存在的漏检、误检问题, 本文提出一种基于 ResNet-LSTM-差分阈值的心电信号特征点检测优化算法。本研究利用自适应阈值对心电信号特征点进行标记, 然后采用 ResNet-LSTM 模型对标注有特征点的心电信号数据进行训练, 最后结合差分阈值法在决策阶段并行检测心电信号 R 波, 当神经网络模型或阈值法中的任一方法成功检测到 R 波时, 该检测即为真正例。实验结果表明, 该方法在 MIT-BIH 数据库上的 R 波检测准确率达到 99.4%, 相较于单一阈值法和传统深度学习方法, 提高了检测精度和计算效率。提出的 ResNet-LSTM-差分阈值心电信号特征点检测方法有效提高了心电信号特征点检测的准确率和鲁棒性, 在面对复杂、多变的心电信号时, 实现了高效、精准、实时的特征点检测, 为各类医疗设备与监护系统提供了广泛的应用前景。

关键词: 心电信号; R 波检测; 深度学习; 体外反搏

中图分类号: TN98 **文献标识码:** A **国家标准学科分类代码:** 510.40

Research on optimization algorithm for ECG feature point detection based on ResNet-LSTM network

Su Peng¹ Wang Shuhan¹ Pan Guoxin² Zhang Zhongyu¹ Wang Peili³

(1. School of Electromechanical Engineering, Beijing Information Science and Technology University, Beijing 100192, China;
2. National Research Center for Rehabilitation Technical Aids, Beijing Key Laboratory of Rehabilitation Technical Aids for
Old-Age Disability, Key Laboratory of Neuro-functional Information and Rehabilitation Engineering of the Ministry of Civil Affairs,
Beijing 100176, China; 3. The National Research Center for Traditional Chinese Medicine Cardiovascular Diseases at
Xiyuan Hospital, China Academy of Chinese Medical Sciences, Beijing 100091, China)

Abstract: Accurate detection of characteristic points in electrocardiogram (ECG) signals is crucial for medical rehabilitation assistance devices, cardiac monitoring systems, and cardiovascular disease research. To address the issues of missed detections and false alarms in traditional methods, this paper proposes an optimized algorithm for ECG characteristic point detection based on ResNet-LSTM-Differential Threshold. In this study, adaptive thresholding is utilized to label the characteristic points of ECG signals, followed by training the ResNet-LSTM model on the annotated ECG signal data. Finally, the differential threshold method is integrated in the decision-making phase to detect R-waves in parallel. A detection is considered a true positive if either the neural network model or the threshold method successfully identifies an R-wave. Experimental results demonstrate that the proposed method achieves an R-wave detection accuracy of 99.4% on the MIT-BIH database, outperforming both single threshold methods and traditional deep learning approaches in terms of detection precision and computational efficiency. The proposed ResNet-LSTM-Differential Threshold method for ECG characteristic point detection effectively enhances the accuracy and robustness of detection. It enables efficient, precise, and real-time detection of characteristic points even when dealing with complex and variable ECG signals, offering broad application prospects for various medical devices and healthcare systems.

Keywords: ECG signal; R-wave detection; deep learning; external counterpulsation

0 引言

根据 2023 年中国心血管健康与疾病报告, 心血管疾病

(cardiovascular disease, CVD) 持续作为我国居民健康的首要威胁^[1]。在此背景下, 心电图分析技术的持续进步与算法优化具有重要意义, 特别是心电信号中 QRS 波群等特征

点的精确识别能够准确评估心脏电生理活动、提高心电图诊断的准确性。近年来,医疗领域正积极探索利用机器学习以实现心电图(electrocardiogra, ECG)信号的精准分析,该技术不仅能有效减轻医疗行业的工作负担、提升诊断效率,还能为缺乏经验的应用案例提供数据支持,尤其在缺血性疾病的诊断与治疗领域展现出巨大潜力^[2]。

目前国内外针对心电信号特征点检测算法主要包括基于阈值法的传统方法、变换域分析方法、深度学习等方法。阈值法是最早应用于 R 波检测的经典方法,代表性算法包括 Pan-Tompkins 算法,该方法结合带通滤波、微分运算、平方运算和移动积分窗口检测 QRS 波群,并通过自适应阈值识别 R 波。然而,阈值法存在以下问题:个体适应性差,固定阈值难以适应不同患者的心电信号特征,尤其是在心律不齐或心肌病变情况下容易误检或漏检;对噪声敏感,工频干扰、肌电噪声、基线漂移等因素会影响阈值法的检测效果,在运动状态下误检率较高;难以应对复杂心电信号,单一阈值法难以对心律失常患者形态多变的 R 波精准检测^[3]。为提高抗噪性,研究者提出变换域分析方法,利用信号的时频特性进行特征点检测,代表性方法包括:小波变换,基于小波变换的 QRS 检测方法,通过多尺度分析分离噪声和 R 波信号提高检测精度,该方法计算复杂度较高,难以满足实时处理需求;经验模态分解,EMD 能适应性分解 ECG 信号的不同成分,并提取 R 波特征,但该方法易受端点效应影响,分解结果不稳定^[4]。近年来,深度学习技术在心电信号分析中得到了广泛应用,其核心思想是利用神经网络自动提取特征并完成特征点检测,主要方法包括:卷积神经网络-长短期记忆(convolutionl neural networks, long short-term memory, CNN-LSTM)结构通过 CNN 提取局部心电特征,LSTM 处理时序信息,提高 R 波检测精度。但 CNN 对局部特征敏感,难以适应跨个体的心电信号变化;BiLSTM 模型,能够利用前后时序信息,提高特征点检测的鲁棒性,LSTM 计算量较大难以满足实时性要求;基于 Autoencoder 的 R 波检测方法,虽然能够有效学习 ECG 信号特征,但该方法需要大量标注数据,训练成本较高;U-Net + BiLSTM 方法通过语义分割完成心电信号 QRS 波群检测,推理速度较慢^[5]。

目前众多医疗设备的工作都要依赖心电信号特征点的识别与检测,体外反搏装置是一种机械挤压下半身的无创康复辅具,其在心脏舒张期由小腿、大腿及臀部反搏装置贯穿的对肢体加压,将下肢血液驱回心脑血管中达到治疗效果,这一过程要求具备高识别率及强实时性的心电信号特征波检测技术。因此本文以体外反搏设备为应用实例,提出了一种基于 ResNet-LSTM-差分阈值(residual networks, ResNet)融合的 R 波检测方法,不仅优化了 R 波检测的精度、召回率、计算效率,还显著提升了模型在不同患者和复杂噪声环境下的泛化能力,为智能医疗设备、远程心电监测、可穿戴设备等提供了更可靠的心电信号分析

方案。

1 心电信号数据与预处理

在处理实时心电信号时,准确标记 R 波将心电信号切割为单个心拍是实现心电信号精细划分和深入研究的至关重要的步骤。由于 ECG 信号属于微伏级时间序列信号,容易受到外部噪声的干扰,在训练神经网络之前必须进行信号预处理,如降噪、去除基线漂移等^[6]。研究采用小波变换技术对心电信号进行降噪处理,具体步骤如下:

首先,基于 db8 小波基对心电信号对九层小波进行分解,将原始的心电信号根据不同的频率范围分解为不同频率范围的多个分量如表 1 所示,且每个分量对应的频率范围根据小波分解的特性确定如表 2 所示。其次,在不影响其频率特性的同时有效去除噪声,基于各波段在心电信号处理中的特殊地位以及对噪声敏感性的综合考量。将 D1、D2、D8 和 A9 这 4 个关键分量实施置零操作。最后,将经过处理的信号分量进行逆小波变换重构,恢复出一个既平滑又显著降低噪声水平的心电信号,从而实现降噪处理的目标^[7]。

表 1 心电信号中原始信号的频率范围	
Table 1 Frequency range of each signal in ECG signal	
信号名称	频率范围/Hz
ECG	0.25~35
P 波	0.5~20
T 波	0.5~10
QRS 波群	3~30
肌电信号	5~2 100
工频信号	50/60
基线漂移	<1

表 2 心电信号分解后分量的频域范围	
Table 2 Frequency domain range signals of each component after decomposition	
信号分量	频域范围/Hz
D1	90~200
D2	45~90
D3	20~45
D4	11~22
D5	5.625 0~11.250 2
D6	2.812 5~5.625 0
D7	1.406 3~2.812 5
D8	0.703 1~1.406 3
A9	0~0.703 1

原始信号存在明显的低频漂移,导致信号未能集中在基线附近,同时信号中还伴有大量的尖锐波形,这些波形表

现为锯齿状特征,通常是由高频噪声引起的。一方面,在检测心电信号时呼吸运动可能导致胸廓起伏,使心脏位置发生微小改变,影响心电信号的基线产生低频漂移;另一方面,电极与皮肤接触不良导致信号传输不稳定,出现低频漂移现象;检测环境中的电磁干扰,尤其是低频电磁辐射,可能耦合到心电信号中,引起基线的波动。经过去噪处理后,低频漂移和高频噪声显著减弱,信号整体趋于平滑,保留 R 波等重要特征,ECG 信号基线大致回归到 0 处,且信号上的锯齿形波形有显著减少。这表明去噪处理有效地去除信号中的低频和高频噪声成分,提升信号的整体质量^[8-9],ECG 信号在去噪处理前后的对比效果如图 1 所示。

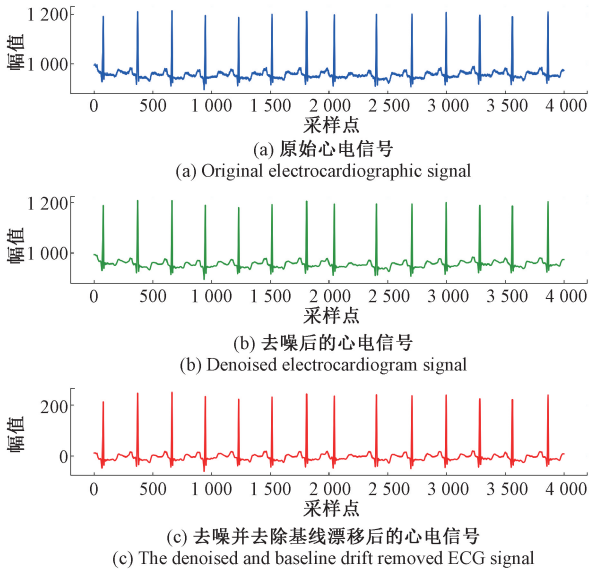


图 1 心电信号去噪前后对比

Fig. 1 Comparison of ECG signals before and after denoising

2 基于动态自适应阈值的特征点标记方法

增强标记在模型训练中发挥重要作用,通过标记可以扩充训练数据的丰富度,引入更多复杂的样本情况,从而提升模型的鲁棒性与泛化能力,使其能够更好地应对现实场景中的多变情况。本研究创新地运用滑动窗口技术,通过对高维数据进行分块处理筛选出冗余信息,提升了特征提取过程中的准确性与效率,为后续模型训练奠定基础。同时,引入自适应阈值依据 ECG 信号的实时变化动态调整阈值范围,无论面对不同个体间的生理差异,还是同一人在不同生理状态下的信号波动都可以精准适配。此外,为进一步优化检测性能,引入稳定性因子和纠错机制,有效降低了信号处理过程中的误检和漏检情况,提高了检测结果的可靠性。

滑动窗口的长度根据 ECG 信号的采样率和心率范围设置为 10,以确保窗口内至少包含一个完整的 QRS 波群^[10]。在每个滑动窗口内,计算信号的平均振幅并加上一个标准差的倍数以允许一定的波动范围,并据此设定一个

初始阈值为式(1)。 μ 为每个滑动窗口中信号的平均振幅, σ 为标准差, k 为常数。随着滑动窗口的移动即在每个心跳周期后,不断更新阈值以适应信号变化,设当前滑动窗口的信号数据为 x_i ,则窗口内的平均振幅和标准差计算为式(2)、式(3),更新的阈值是窗口内的平均振幅加上标准差的一个倍数,并考虑前一个窗口的阈值以实现平滑过渡式(4),其中 α 是一个介于 0 和 1 之间的权重参数,用于平衡前一个窗口阈值和当前窗口统计量的影响^[11]。

$$T_{initial} = \mu + k \times \sigma \quad (1)$$

$$\mu_{window} = \frac{\sum_{i=1}^n x_i}{n} \quad (2)$$

$$\sigma_{window} = \sqrt{\frac{\sum_{i=1}^n (x_i - \mu_{window})^2}{n}} \quad (3)$$

$$T_{updated} = \alpha \times T_{previous} + (1 - \alpha) \times (\mu_{window} + k \times \sigma_{window}) \quad (4)$$

标记阶段在经过去噪、滤波等一系列预处理的心电信号输入时开始,遍历信号计算平均值与标准差从而设定初始阈值,滑动窗口伴随多次阈值更新,当达到判断条件 $x_i > T_{updated}$ 且 $x_i > x_{i-1}$, $x_i > x_{i+1}$ 标记到一次 R 峰,具体如图 2 所示。




图 2 自适应动态阈值调整

Fig. 2 Adaptive threshold adjustment

根据以上 R 波标记条件,自适应阈值的设计条件如下:当监测到的心电图波形峰值整体表现出上升趋势时,自适应阈值应相应地进行递增调整,相反自适应阈值随之适度减少。具体调整规则为:当在特定时间窗口内只检测到一个波峰时,说明当前阈值设定较为合理,无需调整;当检测到两个及以上波峰时,说明当前阈值可能过于宽松,导致误检。如果次波峰的振幅接近主波峰,调整幅度基于次波峰与主波峰振幅之差的百分比来确定,将阈值上调为该差值的 50%。心电信号 R 波标记结果如图 3 所示^[12]。

标记方法在心电信号起始阶段快速确定合适阈值进行 R 波波峰标记。通过此算法标记到的 R 峰位置准确合理,与原始心电信号中的位置相吻合,视觉上无明显偏差。因此可以确认研究提出的 R 峰标记方法合理可行,达到预期目标。与固定阈值方法相比,其能够更好地适应不同患者




图 3 心电信号 R 波标记结果

Fig. 3 Marking results

表 3 根据 AAMI 标准划分数据集

Table 3 Data divided according to AAMI standards

组名	记录编号
P1	101 106 108 109 112 114 115 116 118 119 122 124 202 203 205 207 208 209 215 220 223 230
T1	100 103 105 111 113 117 121 123 200 202 210 212 213 214 219 221 222 228 231 232 233 234

instrumentation)标准对模型的性能进行分析和对比,评估其在分类准确性、灵敏度和特异性方面的表现^[15]。

3.1 模型架构

增加训练层深度可能会导致退化问题,本文引入 ResNet 作为解决方案。残差结构单元中假设输出 $y = F(x)$ 和 $y = F(x) + x$ 分别计算在有映射和无映射情况下的梯度,在有映射情况更不容易出现梯度消失的风险,如式(5)所示, $F(x)$ 为 x 和真实值之间的一个残差^[16],如图 4 所示。




图 4 ResNet 原理图

Fig. 4 ResNet schematic diagram

$$\frac{\partial y}{\partial w} = \frac{\partial y}{\partial F(x)} \frac{\partial F(x)}{\partial x} \frac{\partial x}{\partial w} + \frac{\partial y}{\partial x} \frac{\partial x}{\partial w} = \frac{\partial F(x)}{\partial x} \frac{\partial x}{\partial w} + \frac{\partial x}{\partial w} \tag{5}$$

$$\frac{\partial F(x)}{\partial x} = \frac{\partial F(x)}{\partial x} \frac{\partial x}{\partial w} \tag{6}$$

本研究基于 ResNet-18 网络架构对心电信号数据进行处理。首先,将原始心电信号转换为尺寸为 (21×60) 的二维图像形式,作为网络的输入数据。ResNet-18 网络包含 5 个核心模块,每个模块均由批归一化 (Batch

心电信号的多样性以及同一患者在不同状态下的信号波动,提高了 R 峰识别的准确性。

3 训练特征点识别的神经网络模型

对平滑的心电信号进行特征点标记后,研究采用 ResNet 与 LSTM 相结合的混合模型利用时间和频率信息提取数据特征,处理后的心电信号按一定比例划分为训练集 P1 和测试集 T1 如表 3 所示^[13-14]。

输入至 ResNet-LSTM 模型中进行训练和评估,最终采用 AAMI (association for the advancement of medical

Normalization)、ReLU 激活函数以及最大池化层 (Max Pooling) 组成。网络的输入维度可根据具体数据集的特性灵活调整,例如 $(18 \times 21 \times 60)$ 或 $(21 \times 21 \times 60)$,分别对应于电极通道数、时间窗口长度以及频率成分的分布特征。

随着网络层次的加深,特征提取过程从粗粒度逐渐过渡到细粒度,特征图的维度逐层递减,从而捕捉到心电信号中不同层次的特征信息。最终,通过自适应平均池化层 (adaptive average pooling) 将特征图压缩为固定尺寸,并经过平展化操作 (Flatten) 转换为 512 维的特征向量。通过结合 CNN 和 LSTM,模型能够既捕捉到局部特征,又能有效处理时序依赖,从而提高对复杂时间序列信号的分析精度。

LSTM 模型作为 RNN 的延伸,已在多个依赖时间或基于序列的数据领域展现出其有效性。重要的是,LSTM 设计解决了 RNN 在长期依赖数据上易发生的梯度消失现象,实现在不丢失细胞状态信息的前提下进行长距离的信息传输^[17],如图 5 所示。其中, f_t, i_t, C_t, O_t 各组件分别对应于遗忘门、输入门、单元状态以及输出门,输入序列记作 x_t , 前一个单元块的输出表示为 h_{t-1} , 前一个存储块的状态值则表示 C_{t-1} , 状态更新过程以符号 C'_t 标记,权重参数与偏置参数分别用 W 和 b 来代表,输入门通过偏置参数来创建新的 R 峰位置信息,输出门生成当前心电信号 R 峰位置信息^[18]。

ResNet 从数据中提取图像特征并转化为 512 维的矢量值,矢量值被作为输入传递给 LSTM 网络,采用具有单个隐藏层的 LSTM 模型对提取的特征进行深入的时间序列分析。最后,通过输出层中 Dropout 和 ReLU 层,结合线性分类器,实现对特征的有效分类。ResNet-LSTM 网络示意图如图 6 所示。混合模型的设计充分利用 ResNet 在图像特征提取方面的优势,以及 LSTM 在处理时间序列数据方面的特长,从而提高 R 波检测的准确性。




图 5 LSTM 单元结构
Fig. 5 LSTM unit structure

3.2 模型性能评估

遵循美国医疗仪器促进协会(The Association for the Advancement of Medical Instrumentation, AAMI)建议标准,研究定义以下准则:若预测的 R 峰位于真实 R 峰 100 ms 的时间窗内,则视为真阳性(TP);超出此范围则判定为假阳性(FP);而假阴性(FN)则代表未被检测到的 R 峰。采用 4 个关键评价指标对研究方法进行性能评估:灵敏度(sensitivity, Se)、正阳性率(positive predictive rate, Ppr)、F1 值以及检测错误率(detection error rate, DER)^[19]。其中, F1 值作为灵敏度和正阳性率的调和平均,能够综合反映方法的检测准确度和召回率,而 DER 则通过计算假阳性和假阴性在总检测中的比例,来直观体现方法的整体错误率,二者能够更为全面地反映方法的整体性能。具体公式如下:

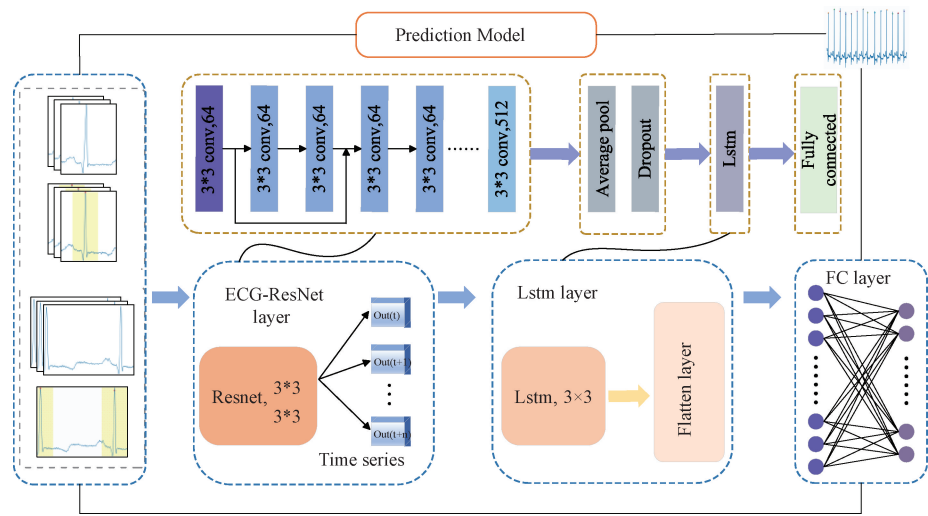


图 6 ResNet-LSTM 网络示意图
Fig. 6 Schematic diagram of ResNet-LSTM network

$$Se = \frac{TP}{TP + FN} \quad (7)$$

$$Ppr = \frac{TP}{TP + FP} \quad (8)$$

$$F1 = \frac{2 \times Se \times Ppr}{Se + Ppr} \quad (9)$$

$$DER = \frac{FN + FP}{TP + FN} \quad (10)$$

为了最大化融合模型的性能表现,研究实施参数优化过程,选择直接影响模型的收敛速度和稳定性的学习率和决定模型能否充分学习数据特征的程度的训练迭代次数(Epoch)这两个核心参数,调参过程严格遵循控制变量的原则,经过系统的调优实验,最终确定最优参数配置如表 4 所示。

学习率是影响神经网络收敛性能的重要参数。过大的学习率可能导致网络参数无法收敛到最优值,而过小的学习率则可能导致网络训练过程缓慢,甚至陷入次优解。

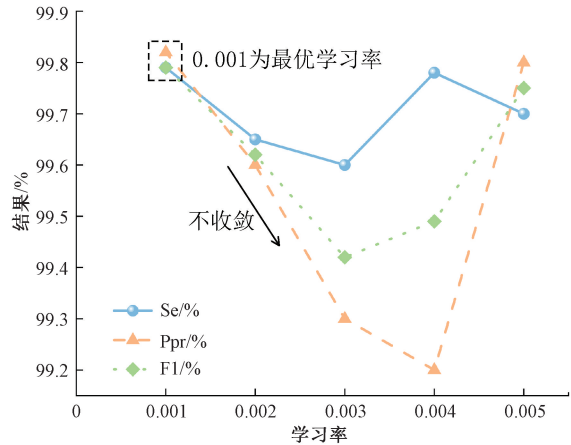
表 4 最优参数选择

Table 4 Optimal parameter selection


参数名	调参范围	最优参数
学习率	$5 \times 10^{-4} \sim 5 \times 10^{-3}$	0.001
Epoch	20~100	52
Batch_size	8~64	50
T1	0.3~0.8	0.5
T2	0.1~0.5	0.4
T3	0.1~0.5	0.3

研究设定 $5 \times 10^{-4} \sim 5 \times 10^{-3}$ 的调参范围以确定最适合本模型的学习率,并进行对比实验。实验结果得知当学习率为 0.001 时,模型在灵敏度(Se)、正阳性率(Ppr)和 F1 值这 3 个评价指标上均表现出较佳的性能。虽然在学习率为 0.000 6 时,灵敏度(Se)达到最高,但正阳性率(Ppr)和综合指标 F1 值却略低。综合考虑 3 个评价指标的表现,

以及模型的稳定性和泛化能力,选择 0.001 作为最优的学习率,实验结果如图 7(a)、(b)所示。



(a) 学习率0.001-0.005调参结果
(a) Learning rate 0.001-0.005 tuning results



(b) 学习率 5×10^{-4} - 9×10^{-4} 调参结果
(b) Learning rate 5×10^{-4} - 9×10^{-4} tuning results

图 7 学习率调参结果

Fig. 7 Results of learning rate parameter tuning

Epoch 代表一次完整的数据集在神经网络模型中前向传播和反向传播的过程,通过观察每个 Epoch 的训练损失和验证损失,可以更好地了解模型的训练过程。经多次试验后,选择 12、32、52、72 和 100 这 5 个 Epoch 值进行对比实验。随着 Epoch 的增大,模型的预测性能也在逐步提高。当 Epoch 为 52 时,模型在灵敏度 (Se)、正阳性率 (Ppr) 和 F1 值这 3 个评价指标上均达到较高性能,分别为 99.76%、99.87% 和 99.81%。而当 Epoch 继续增大时,由于过拟合模型的预测性能却出现轻微下降。因此,选择 Epoch 为 52 作为最优的迭代次数,结果如图 8 所示。

经调参,确定了结合 ResNet 和 LSTM 检测心电信号 R 波波峰模型的最优参数,这不仅提升模型预测性能与稳定性,为后续心电信号分析提供有力支撑,其调参方法与经验也能为其他深度学习的心电信号分析任务提供参考。




图 8 Epoch 调参结果

Fig. 8 Epoch tuning results

4 分析与验证

4.1 联合检测实验与分析

训练后的神经网络模型单一检测心电信号 R 波可能会受到个体差异的影响,阈值法与神经网络模型结合可以进一步提升检测效率、增强方案的鲁棒性和泛化能力。结合差分阈值法和深度学习模型的关键在于对心电信号的检测是并行关系,无论是神经网络模型检测到 R 波波峰还是阈值法检测到 R 峰都作为真正例。决策逻辑图如图 9 所示。

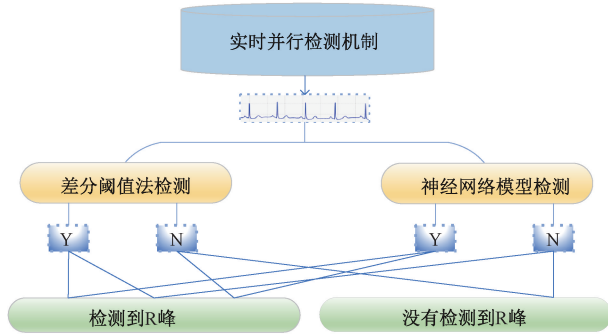


图 9 决策逻辑图

Fig. 9 Decision logic diagram

单一的传统阈值法难以适应不同个体生理特征差异和环境变化因素,经实验证明测试者的情绪和汗液多少会使心电信号产生噪声或者信号变异也会对阈值法造成干扰^[20]。如果只用网络模型对心电信号 R 波进行检测则大大降低推理效率,有可能会情绪波动心率加快导致处理时间超过心率变化时间窗口的情况^[21]。因此用神经网络模型对阈值法检测做保障,二者同时对实时的心电信号进行检测,使得其在维持高精度的同时也具备快速响应能力。

差分阈值法在决策阶段中目的是快速排除大部分非 R 波区域,减少后续深度学习模型的搜索空间。首先一阶差分计算相邻采样点之间的差值,反映信号的变化率,如

式(11)所示。在心电信号中,R 波的上升沿和下降沿斜率较大,因此一阶差分在 R 波处会出现明显的峰值,设定一个合适的阈值,当一阶差分的绝对值超过该阈值时,判定为 R 波候选点,但是这个阈值是固定的无法根据具体的心电信号特性进行调整。二阶差分计算一阶差分序列的差值,反映信号斜率的变化率。在 R 波处,一阶差分由正转负或由负转正,二阶差分会出现过零点,如式(12)所示^[22]。

$$f'(x) = \frac{df(x)}{dx} = \lim_{h \rightarrow 0} \frac{f(x+h) - f(x)}{(x+h) - x} \tag{11}$$

$$f'(x_k) = \frac{f'(x_{k+1}) - f'(x_k)}{x_{k+1} - x_k} \tag{12}$$

通过阈值法大部分较高 R 峰均已筛选出来完成标记,少部分 R 峰由于阈值设置不能灵活调整不能够完全检测出来,如图 10(a)所示。

当阈值不能灵活变动,或使用阈值法时受个体差异、心律失常等不确定因素影响出现漏检时,训练完成的神经网络会对实时心电信号进行检测。差分阈值法和神经网络协同作用下检测心电信号 R 波波峰可以直观看检测到没有出现漏检或者误检情况,相比较单独使用阈值法有较大提升,结果如图 10(b)所示。

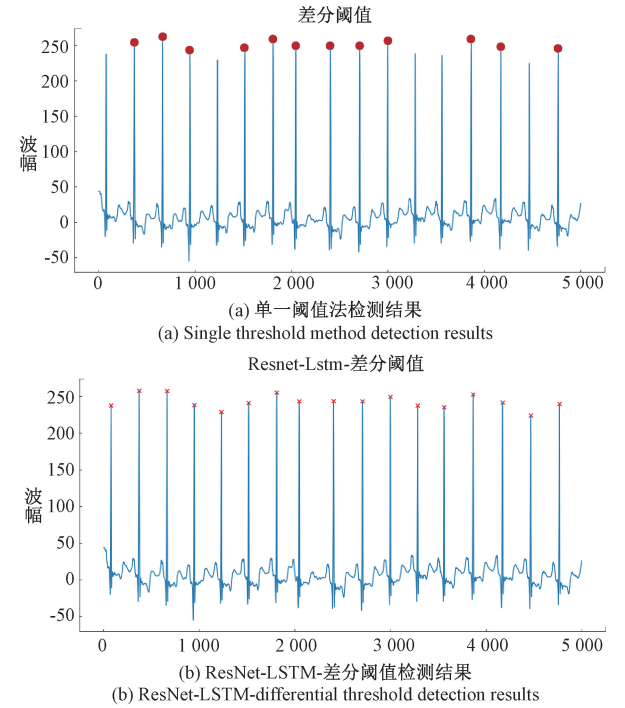


图 10 检测方法对比图

Fig. 10 Comparison chart of detection methods

利用 T1 数据组中的 22 组心电数据文件作为信号源 $x(i)$, 检测心电信号 R 波波峰,并对结果量化分析^[23]。使用 ResNet-LSTM-差分阈值融合算法检测 R 峰,结果与 MIT-BIH 数据库中标注文件对比,计算识别正确识别 R 峰总数 TP_R ,误检数 FN_R ,漏检数 FP_R ,敏感度 Se_R 和准确率 Acc_R 等,结果如表 5 所示。在表 5 中,R 峰检测总数

为 49 712,只有 64 个 R 峰没有被准确检测到,115 个 R 峰没有检测到。对于改进前的算法利用相同心电数据集进行测试,结果显示其平均漏检率达到了 15%,误检率为 12%。主要原因在于,原算法采用相对简单的特征提取和判断机制,在处理复杂心电信号时,难以准确识别特征点。当信号受到较强噪声干扰,或是 R 波形态不典型时,原算法容易出现漏检。由于缺乏有效的阈值自适应调整策略,对于类似特征点的干扰信号,原算法容易误判,从而导致较高的误检率。改进后的阈值+ResNet+Lstm 算法平均漏检率大幅降至 0.4%,误检率降低到 0.5%。

表 5 T1 测试集对研究方法进行评估

Table 5 T1 evaluates the method proposed in this article

编号	TP_R	FN_R	FP_R	$Se_R/\%$	$Acc_R/\%$
100	2 280	0	0	100	99.91
103	2 085	0	0	100	99.96
105	2 527	41	25	98.33	98.74
111	2 125	2	1	99.91	98.97
113	1 796	0	0	100	99.95
117	1 533	0	0	100	99.88
121	1 864	0	0	100	99.86
123	1 520	0	0	100	99.92
200	2 600	2	2	99.92	97.63
202	2 133	2	1	99.91	98.77
210	2 640	5	1	99.70	98.33
212	2 754	0	0	100	99.83
213	3 250	0	0	100	99.92
214	2 262	3	1	99.87	98.56
219	2 150	1	4	99.95	98.73
221	2 428	1	0	99.96	99.84
222	2 434	54	2	97.83	96.33
228	2 050	3	5	99.85	97.65
231	1 570	0	0	100	99.78
232	1 780	0	22	100	98.56
233	3 078	1	0	99.97	98.38
234	2 754	0	0	100	99.96
总	49 613	115	64	99.76	99.47

将心电信号特征点检测优化算法与传统体外反搏设备应用的心电信号检测法:差分阈值法、小波变换法、模态分析法作对比,结果数据如表 6 所示。可以得出,研究所提出的算法比同类型的差分阈值法以及小波变换法准确率、灵敏度、精度均有提升,满足体外反搏设备工作中 R 峰定位需要。

同时将研究方法与单一深度学习方法进行对比。选取进行创新性改进的 U-net&BiLSTM 网络和首次将堆叠式自动编码器应用于 ECG 中的 QRS 波群检测和 R 峰定

表 6 研究方法与传统阈值法对比效果

Table 6 Comparison of the effectiveness between the method proposed in this article and the traditional threshold method

R 波检测方法	Se_R	Acc_R	Precision	Recall
差分阈值法 ^[24]	99.70	99.62	99.68	99.70
小波变换法 ^[25]	99.88	99.83	99.85	99.88
模态分析法 ^[26]	99.23	97.05	97.08	99.23
本文方法	99.76	99.93	99.93	99.76

位问题 Autoencoders 方法进行对比,阈值结合神经网络模型的检测方法与单一网络模型方法的对比效果如表 7 所示。

表 7 融合算法与单一深度学习方法对比效果

Table 7 Comparison of the effectiveness between the method proposed in this article and a single deep learning method

模型	TP_R	FN_R	FP_R	$Se_R/\%$	$Acc_R/\%$
U-net&BiLSTM ^[27]	49 470	141	85	99.56	97.56
Autoencoders ^[28]	49 329	378	112	99.76	98.76
本文方法	49 613	120	64	99.76	99.93

在 T1 相同数据集下进行消融实验进一步验证优化算法的性能,如表 8 所示。消融实验设计如下:从原始的 ResNet-LSTM-差分阈值融合算法中,分别去除 ResNet 模块、LSTM 模块以及差分阈值法,构建不同的简化模型。在相同数据集上进行训练和测试。采用 Sensitivity、Accuracy、F1 和 DER 作为评价指标。在 R 波波峰的检测结果中阈值+ResNet 模型优于其余两者,阈值+ResNet+Lstm 平均性能最好、指数最高,结果如图 11 所示。因此,研究的阈值+ResNet+Lstm 模型对心电信号 R 波波峰识别更为有效。

表 8 消融实验指标分析

Table 8 Analysis of ablation experiment indicators

模型	$Se_R/\%$	$Acc_R/\%$	F1/ $\%$	DER/ $\%$
仅 ResNet	98.42	98.31	98.36	1.68
仅 LSTM	97.83	97.96	97.89	2.04
仅阈值法	96.71	97.12	96.91	3.09
ResNet+LSTM	99.01	99.12	99.06	0.99
本文方法	99.76	99.93	99.84	0.24

4.2 有效性验证与分析

为验证心电信号特征点检测优化算法在实际医疗应用中的具体有效性,将算法研究与具体相关医疗设备结合研究其工作情况,全面评估算法性能及其对医疗设备工作效能的提升作用。以体外反搏设备为研究对象,验证优化




图 11 消融实验在 T1 数据集上的表现

Fig. 11 Performance of ablation experiment on T1 dataset

算法可靠性及设备血流增强效果,联合医院超声科室进行辅助循环康复实验,如图 12 所示。本试验选取 10 名健康志愿者(平均体重 65 kg,身高 170 cm),使用薄膜压力传感器和心电、脉搏监测系统,在标准姿势下采集一个康复周期内的人体生理数据。实验前静坐 15 min 稳定心率,利用优化算法检测 R 波驱动电机带动束紧带周期工作,采集开始与 5 min 后数据,取稳定数据平均值分析。



图 12 体外反搏试验验证优化算法有效性

Fig. 12 Verification of the effectiveness of the method proposed in this paper by extracorporeal counterpulsation test

对比 3 种工作情况下的血管血容积相对于静息状态的增量,未预紧状态相对于静息增长 12.5%,经过预紧后增长 22%,经过预紧及延时后,增幅达到 44.6%,峰值幅值提高 80 左右,整个周期的血容积也显著提高。

在舒张期,心脏舒张,使血液流回心脏,此时为挤压最佳时间点,在静息状态中,由于没有对肢体施加压力,所以平稳下降。在增加体外反搏设备进行挤压后,3 种情况均出现反搏波,此波代表由于束紧带给予肢体压力,增大血液回流量,并且和峰值情况相似,在经历预紧及延时测量后的反搏波最为明显,增长率为 48.9%,未预紧和经过预紧分别增长 34.1%和 39.4%,具体如图 13 所示。

使用多普勒超声检测仪检测血液流速,发现在经过设备工作后,肾动脉的血流速从 82.4 cm/s,提高到 121.2 cm/s,增长率为 47.09%,该优化算法特征点检测准确、可靠,提高体外反搏设备的工作效率,结果如图 14(a)

和(b)所示。

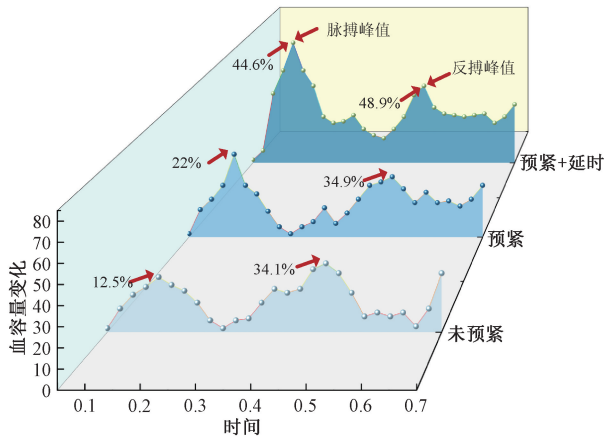




图 13 工作过程中血容积增长效果

Fig. 13 Effect of blood volume growth during working process



(a) 静息时血流速
(a) Resting blood flow velocity



(b) 工作后血流速
(b) Blood flow velocity after operation

图 14 体外反搏设备应用本文算法工作前后效果图

Fig. 14 Effect diagrams of the extracorporeal counterpulsation device before and after it operates using the algorithm proposed in this paper

5 结 论

研究提出了一种基于 ResNet-LSTM 网络和差分阈值法的心电信号特征点检测优化算法,首先该算法结合了

ResNet 提取特征点的能力和 LSTM 处理时间序列数据上的优势,其次利用差分阈值法解决神经网络面对心电信号突变和噪声方面的不足,利用神经网络模型和差分阈值法并行处理心电信号的机制,解决传统方法在复杂多变心电信号中的漏检和误检问题,提高了算法对心电信号特征点的检测精度和鲁棒性。实验结果表明,该算法在检测心电信号 R 波时,准确率达到 99.93%,显著提高了检测精度和效率。体外反搏设备试验中使用该算法工作后血液回流速度增长 47.09%,回流量增长显著,验证了算法有效性。为同类医疗设备和医护系统提供技术支持,具有重要的临床应用价值。

参考文献

- [1] 刘明波,何新叶,杨晓红,等.《中国心血管健康与疾病报告 2023》要点解读[J]. 临床心血管病杂志, 2024, 40(8): 599-616.
LIU M B, HE X Y, YANG X H, et al. Interpretation of report on cardiovascular health and diseases in china 2023[J]. Chinese General Practice, 2024, 40(8): 599-616.
- [2] 肖前军. 体外反搏治疗效果自动优化算法与实现[J]. 信息技术与网络安全, 2018, 37(3): 154-157.
XIAO Q J. Automatic optimization algorithm and implementation for external counterpulsation therapy effect [J]. Information Technology & Network Security, 2018, 37(3): 154-157.
- [3] 苏鹏,郭强,王思锴,等. 基于分布计算的心电特征波检测算法研究[J]. 仪器仪表学报, 2023, 43(11): 142-150.
SU P, GUO Q, WANG S K, et al. Research on ECG characteristic wave detection algorithm based on distributed computing[J]. Chinese Journal of Scientific Instrument, 2023, 43(11): 142-150.
- [4] 林金朝,李必禄,李国权,等. 基于集合经验模态分解和信号结构分析的心电信号 R 波识别算法[J]. 电子与信息学报, 2021, 43(8): 2352-2360.
LIN J CH, LI B L, LI G Q, et al. R-wave recognition algorithm for ECG signals based on ensemble empirical mode decomposition and signal structure analysis[J]. Journal of Electronics & Information Technology, 2021, 43(8): 2352-2360.
- [5] 赵雅琴,孙蕊蕊,吴龙文,等. 基于改进深度生成对抗网络的心电信号重构算法[J]. 电子与信息学报, 2022, 44(1): 59-69.
ZHAO Y Q, SUN R R, WU L W, et al. ECG signal reconstruction algorithm based on improved deep generative adversarial network [J]. Journal of

- Electronics & Information Technology, 2022, 44(1): 59-69.
- [6] KUMAR A, TOMAR H, MEHLA V K, et al. Stationary wavelet transform based ECG signal denoising method[J]. ISA transactions, 2021, 114: 251-262.
- [7] EL BOUNY L, KHALIL M, ADIB A. ECG heartbeat classification based on multi-scale wavelet convolutional neural networks[C]. ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing(ICASSP), 2020: 3212-3216.
- [8] LI H Q, WANG X F, CHEN L CH, et al. Denoising and R-peak detection of electrocardiogram signal based on EMD and improved approximate envelope [J]. Circuits, Systems, and Signal Processing, 2014, 33: 1261-1276.
- [9] YUEN B, DONG X D, LU T. Inter-patient CNN-LSTM for QRS complex detection in noisy ECG signals[J]. IEEE Access, 2019, 7: 169359-169370.
- [10] AZIZ S, AHMED S, ALOUINI M S. ECG-based machine-learning algorithms for heartbeat classification[J]. Scientific Reports, 2021, 11(1): 18738.
- [11] ZAHID M U, KIRANYAZ S, GABBAOUI M. Global ECG classification by self-operational neural networks with feature injection[J]. IEEE Transactions on Biomedical Engineering, 2022, 70(1): 205-215.
- [12] GE ZH Y, CHENG H Q, TONG ZH, et al. A knowledge-driven graph convolutional network for abnormal electrocardiogram diagnosis[J]. Knowledge-Based Systems, 2024, 296: 111906.
- [13] STRODTHOFF N, WAGNER P, SCHAEFFTER T, et al. Deep learning for ECG analysis: Benchmarks and insights from PTB-XL [J]. IEEE Journal of biomedical and Health Informatics, 2020, 25(5): 1519-1528.
- [14] HE K M, ZHANG X Y, REN SH Q, et al. Deep residual learning for image recognition [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [15] TAO L, LIU B N, LIANG W. Automated detection of arrhythmia for hybrid neural network of LSTM-residual with multi-information fusion[J]. Mathematical Problems in Engineering, 2021, 2021(1): 2831064.
- [16] CAI J, ZHOU G, DONG M K, et al. Real-time arrhythmia classification algorithm using time-domain ECG feature based on FFNN and CNN[J]. Mathematical Problems in Engineering, 2021, 2021(1): 6648432.
- [17] LONDHE A N, ATULKAR M. Semantic segmentation of ECG waves using hybrid channel-mix convolutional and bidirectional LSTM[J]. Biomedical Signal Processing and Control, 2021, 63: 102162.
- [18] NURMAINI S, DARMAWAHYUNI A, RACHMATULLAH M N, et al. Beat-to-beat electrocardiogram waveform classification based on a stacked convolutional and bidirectional long short-term memory[J]. IEEE Access, 2021, 9: 92600-92613.
- [19] LI W, GAO J. Automatic sleep staging by a hybrid model based on deep 1D-ResNet-SE and LSTM with single-channel raw EEG signals[J]. PeerJ Computer Science, 2023, 9: e1561.
- [20] TUECHE F, MOHAMADOU Y, DJEUKAM A, et al. Embedded algorithm for QRS detection based on signal shape [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-12.
- [21] CAI W, HU D. QRS complex detection using novel deep learning neural networks [J]. IEEE Access, 2020, 8: 97082-97089.
- [22] SRAITHI M, JABRANE Y, HAJJAM EL H A. A robustness evaluation of machine learning algorithms for ECG myocardial infarction detection[J]. Journal of Clinical Medicine, 2022, 11(17): 4935.
- [23] 梁晓洪, 宋宁宁, 刘成友, 等. 基于深度学习的心电信号特征点检测的算法研究[J]. 生物医学工程研究, 2023, 42(4): 1672-6278.
- LIANG X H, SONG N N, LIU CH Y, et al. Research on algorithm for ECG signal feature point detection based on deep learning[J]. Journal of Biomedical Engineering Research, 2023, 42(4): 1672-6278.
- [24] ZHANG Z, LI Z Y, LI ZH Y. An improved real-time r-wave detection efficient algorithm in exercise ECG signal analysis[J]. Journal of Healthcare Engineering, 2020, 2020(1): 8868685.
- [25] MERAH M, ABDELMALIK T A, LARBI B H. R-peaks detection based on stationary wavelet transform[J]. Computer Methods and Programs in Biomedicine, 2015, 121(3): 149-160.
- [26] 姚晰童, 代煜, 张建勋, 等. 陡脉冲干扰下的心电信号滤波及 QRS 提取[J]. 工程科学学报, 2020, 42(5): 654-662.
- YAO X T, DAI Y, ZHANG J X, et al. ECG signal filtering and QRS extraction under steep pulse interference [J]. Chinese Journal of Engineering,

2020, 42(5): 654-662.

- [27] HE R, LIU Y, WANG K, et al. Automatic detection of QRS complexes using dual channels based on U-Net and bidirectional long short-term memory[J]. IEEE Journal of Biomedical and Health Informatics, 2020, 25(4): 1052-1061.
- [28] BELKADI M A, DAAMOUCHE A, MELGANI F. A deep neural network approach to QRS detection using autoencoders [J]. Expert Systems with Applications, 2021, 184: 11.

作者简介

苏鹏, 博士, 教授, 主要研究方向为医疗机器人技术、智能机械装备设计与控制。

E-mail: supeng@bistu.edu.cn

王书涵, 硕士研究生, 主要研究方向为智能机械装备设计与控制。

E-mail: 1256620541@qq.com

王培利(通信作者), 博士, 主任医师, 主要研究方向为中西医结合心血管研究、心电原理与应用等。

E-mail: 191593690@qq.com