

基于心电图信号的人工智能自动诊断在心血管疾病中的应用

陈云帆¹ 叶锦兴¹ 梅小雨¹ 吴志强¹ 杨柳旺¹ 郝禄国^{2,3} 万相奎¹

¹湖北工业大学 太阳能高效利用及储能运行控制湖北省重点实验室,武汉 430068; ²广东工业大学 信息工程学院,广州 510006; ³普立(广州)健康科技有限公司,广州 510663

通信作者:万相奎,Email: xkwan@hbut.edu.cn

DOI:10.13333/j.cnki.cjcpe.2025.02.003

[摘要] 人工智能在心血管疾病诊断中的应用备受关注。心电图(ECG)作为常见的诊断工具,其准确解读需要专业知识。近年机器学习和深度学习技术在 ECG 自动诊断、预测和筛查方面取得了显著进展。笔者介绍了多用于 ECG 图像识别的卷积神经网络和循环神经网络的深度学习方法,及为深度学习提供训练与测试的常用心电数据库,并综述了基于 ECG 信号的人工智能在心律失常分类、心肌梗死定位的应用与进展,希望为相关领域的科研人员提供参考。

[关键词] 人工智能;心电图;深度学习;卷积神经网络;循环神经网络

Application of artificial intelligence in automated ECG-based diagnosis of cardiovascular diseases


CHEN Yunfan¹, YE Jinxing¹, MEI Xiaoyu¹, WU Zhiqiang¹, YANG Liuwang¹, HAO Lugu^{2,3}, WAN Xiangkui¹

¹Hubei Key Laboratory for High-efficiency Utilization of Solar Energy, Hubei University of Technology, Wuhan 430068, China; ²School of Information Engineering, Guangdong University of Technology, Guangzhou 510006, China; ³Puleap Health Technology Co., Ltd., Guangzhou 510663, China

心血管疾病的患病率和死亡率在持续上升,疾病负担不断加重,因此预防心血管疾病变得尤为重要,包括提前预防、早期发现、准确诊断和及时治疗。近年来,人工智能在医疗健康领域的应用已广泛覆盖,如智能诊疗、虚拟助理、医学影像分析、可穿戴设备监控和电子健康病历管理等。深度学习作为人工智能的核心技术,在心电图(electrocardiogram, ECG)自动诊断和心血管疾病预测方面展现了巨大潜力和价值。

深度学习算法对 ECG 信号的检测流程通常包括三个核心步骤,如图 1 所示:首先是 ECG 信号的预处理,以确保数据的准确性和可靠性;然后是设计深度

学习模型进行特征学习和提取,自动提取关键特征;最后是模型训练和预测,基于提取的特征对心电信号进行分类。经过严格训练的深度学习网络架构,能够迅速捕捉 ECG 信号中的异常特征,并进行准确分类和预测。在这一过程中,卷积神经网络(convolutional neural network, CNN)和循环神经网络(recurrent neural networks, RNN)等深度学习架构发挥着重要作用。本文旨在系统梳理和评述基于 ECG 的深度学习算法的原理及应用现状,探讨深度学习技术在心血管疾病自动诊断和预测中的应用前景,以为相关领域的研究和实践提供有价值的参考。



注:ECG=心电图。

图 1 基于深度学习算法的心电图信号的分类流程

1 ECG 自动诊断的深度学习算法

现代深度学习算法在 ECG 图像处理方面相比传统方法具有高精度、自动特征学习、高效数据处理及强泛化能力等优势。通过多层神经网络,深度学习能自动从海量 ECG 数据中学习复杂特征,实现精

准的信号分析和诊断,尤其在识别心律失常、心肌缺血等疾病上表现卓越。相比传统的手工设计特征和规则,深度学习能更全面捕捉 ECG 信号的复杂变化,提升处理复杂或异常信号时的精度。随着计算能力提升,深度学习能高效处理大规模 ECG 数据集,快速完成分析诊断,提升医疗服务效率。同时,

深度学习通过大数据训练,具备更强的泛化能力,对未见的 ECG 信号也能保持高诊断准确性,而传统方法在这方面相对较弱。

在 ECG 自动诊断方面,CNN 和 RNN 是两种非常重要的模型,它们各自有不同的模型变种。CNN 主要通过堆叠多个卷积层、池化层和全连接层来构建,旨在逐层抽取 ECG 特征,最终用于分类或回归。卷积层利用多核滑动窗口技术提取局部特征生成特征图;池化层随后降低维度,减少计算并增强鲁棒性;最终,全连接层将特征映射至目标类别,完成诊断或预测任务。

RNN 擅长处理文本、音频等序列数据,通过隐藏层循环连接保留历史信息。但处理长序列时易遇梯度消失或梯度爆炸问题。长短时记忆网络(long short term memory,LSTM)作为 RNN 改进版,采用遗忘、输入、输出三门机制解决梯度难题,有效捕捉长期依赖。LSTM 架构含输入、隐藏、输出三层,其中隐藏层含多个 LSTM 单元,各单元运用门控机制处理信息,输出层则基于隐藏层输出计算当前预测。

对于 CNN 及 RNN 模型的评价,主要有准确率、损失函数和 F1 分数。其中准确率是衡量模型正确分类或预测的比例。损失函数用于衡量模型预测值与真实值之间的差异,通常通过优化损失函数来训练模型。F1 分数是精确率和召回率的调和平均,用于综合评价模型的性能。

1.1 CNN CNN 作为图形处理的重要方法在心电信号检测领域优势显著,主要归功于其强大的局部特征提取与时空信息整合能力。CNN 能有效识别 ECG 复杂波形,通过卷积层捕获心电特征,池化层减少噪音干扰,加之深度结构提高识别精度。通过卷积层与池化层的多次叠加重复,经全连接层拟合强化,最终输出分类结果。这一深度学习特性极大促进了心律失常的高效准确诊断,成为心电分析领域的关键技术。迄今为止,已经有很多研究人员将 CNN 及相关

模型运用到基于 ECG 的心血管疾病诊断中,其基础模型结构如图 2 所示。YILDIRIM 等^[1]使用深度卷积神经网络(deep convolutional neural networks,DCNN)模型对 MIT-BIH 数据库中 17 例正常及心律失常患者的长时间心电信号(10 s 单导联 ECG)进行分类取得了 91.33% 的分类准确率。WANG 等^[2]将 CNN 模型与膨胀卷积(dilated convolution)方法相结合,构建了名为 DMSFNet 的模型,实现了多尺度的心电信号特征提取与分类,并对 CPSC-2018 数据库和 CinC-2017 数据库中相应的 6~60 s 的 12 导联 ECG 和 9~60 s 的单导联 ECG 进行学习分析,分别取得了 82.8% 和 81.4% 的平均 F1 分数。在针对 ECG 信号的多分类任务中,平均 F1 分数是一个重要的评估指标,用来衡量分类器的整体性能。一般平均 F1 分数越高代表模型的性能越好。具体而言,平均 F1 分数在计算每个类别的 F1 分数后取平均值,这种方式对所有类别给予相同的权重,提供了关于分类器整体性能的信息。FOTIADOU 等^[3]对胎儿 ECG 进行了深度学习研究,将 CNN 模型、LSTM 模型与膨胀卷积方法结合,试图在不稳定的基线及高信噪比的信号中准确识别胎儿 ECG 的 R 波以确定胎儿心率,该方案经 2013 Physionet/Computing in Cardiology Challenge 数据库的相关验证,取得了 99.6% 的分类准确率。PRABHAKARARAO 等^[4]将 DCNN 与膨胀卷积结合,此外也同时结合了集成学习的方法通过建立 DMSCE 模型开展 ECG 中 R 波峰的检测及心律失常的分类,以多个数据集进行训练与测试,最终在 PTB-XL2020 数据库上取得了 84.5% 的平均 F1 分数。YUN 等^[5]同样利用多个数据集进行 R 波峰的深度学习与测试评估,将 CNN 模型与残差块以及空间锥型池化(atrous spatial pyramid pooling,ASPP)结合,使得模型在节省算力的同时保证了模型在噪声和异常数据干扰下的分类准确性,最终在 MIT-BIH 数据库上取得了 99.94% 的 F1 分数。





图 2 卷积神经网络用于心律失常分类的基础模型结构

1.2 RNN RNN 是深度学习领域中专为处理序列数据而设计的一种模型。RNN 的核心创新在于其循环机制,允许信息在时间序列中流动,从而捕捉

数据间的时序依赖关系^[6]。RNN 模拟既往记忆会影响认知过程的人类学习模式,每个 RNN 单元在每个时间同步接收两个输入:当前时刻的外界输入

(输入层)和前一时刻的隐藏状态(隐藏层),隐藏层间并非独立而是形成循环连接,通过使用激活函数[如双曲正切函数(hyperbolic tangent function, tanh)或线性整流函数(rectified linear units, ReLU)],网络更新其隐藏状态,这一状态可以视为网络对过去序列的记忆。此机制使 RNN 能够处理任意长度的序列,如文本、语音或图像序列数据,适用于诸如语言建模、机器翻译、图像描述等多种任务。在 RNN 的运用中为提高性能提升训练效果,门控 RNN 模型如 LSTM 和门控循环单元(gated recurrent unit, GRU)应运而生,门控机制可以更好地控制信息的流动利于信息的存储和遗忘,显著提高了处理长序列数据的能力。近年来,有很多研究人员将 RNN 及其相关变体模型运用到基于 ECG 的心血管

疾病诊断中,其基础模型结构如图 3 所示。ZHANG 等^[7]提出了一种基于 RNN 和聚类技术的特定患者 ECG 分类算法,自动学习 ECG 信号的时间相关性并处理不同心律的 ECG 特征,该方案在室性(ventricular, VEB)和室上性(supraventricular, SVEB)的分类识别方面,尤其是 SVEB 节律的检出上取得显著改善。ÜBEYLI 等^[8]的研究展示了结合 Lyapunov 指数和 RNN 在 ECG 信号分类中的高效性,为心律失常、心脏疾病的早期诊断提供了有前景的工具。DHANANJAY 等^[9]提出了一种基于 LSTM 与 RNN 相结合的方法来预测正常窦性心律 ECG 信号中的 RR 间期。这项工作旨在利用先前的 RR 间期数据来预测接下来的心跳周期中的 RR 间期,从而帮助分析个体的心率变异性(heart rate variability, HRV)。



注: X_1, X_2, X_n 表示输入的心电信号特征; Y_1, Y_2, Y_n 表示模型的输出结果; Z^{-1} 表示循环连接层中的延迟单元。

图 3 循环神经网络用于心电信号检测的基础模型结构

2 常用 ECG 数据库

在国际心电数据库领域,目前最重要具有权威性的心电数据库有四个:由美国麻省理工学院与 Beth Israel 医院联合构建的 MIT-BIH 心电数据库;由美国心脏学会(American Heart Association, AHA)建立的针对心律失常研究的心电数据库;以及欧盟的两大数据库——Common Standards for Electrocardiography(CSE)心电数据库和 ST-T 心电数据库。除此之外,国际上还有一些其他广泛应用的心电数据库,例如心脏性猝死动态心电图数据库(Sudden Cardiac Death Holter Database),用于心脏骤停研究的数据库;PTB 心电诊断数据库(PTB Diagnostic ECG Database),是一个诊断 ECG

的综合性数据库;以及 PAF 预测挑战数据库(PAF Prediction Challenge Database),专注于心房颤动(简称房颤)预测的数据库等。这些数据库共同为心血管疾病的研究、诊断和治疗提供了宝贵的数据支持。

MIT-BIH 数据库^[10]:该心电数据库是目前在国际上应用最多的数据库,由很多子数据库组成,每个子数据库包含某类特定类型的心电记录。其中 MIT-BIH Arrhythmia database(MITDB)数据库包含来自 47 位不同患者的 48 份 30 min 双通道动态 ECG,采样频率为 360 Hz。

AHA 数据库^[11]:美国国家心肺及血液研究院资助的 AHA 开发了心律失常心电数据库,旨在评估室性心律失常检测效果。其涵盖了 154 名真实病人的 ECG 记录,均来自不同的医疗机构,每个记录

长达 3 h,由 2 个导联信号组成,采样频率 250 Hz。

欧盟 CSE 数据库^[12]:全球每年约 40 万成人及数百万儿童猝死,PhysioNet 建立心源性猝死数据库以促进电生理研究。该心电数据库收录了 1 000 例短时间的心电记录,采用 12 或 15 导联系统,以全面捕捉心脏电活动的细微变化。

欧盟 ST-T 数据库^[13]:由欧洲心脏病学会开发,旨在评估 ST 段和 T 波检测算法性能。该数据库包含来自 79 名受试者的 90 个 2 h 的心电记录片段,其中包括因高血压、心肌缺血、心室舒缩障碍以及药物作用等多种因素引起的异常心电图表现。

心脏性猝死动态心电图数据库^[14]:该数据库包括 23 位心源性猝死患者的 30 min 的 1 个导联心电图记录片段,采样频率为 250 Hz。其中 18 例窦性心律(4 例为间歇性起搏),1 例为连续起搏心律,4 例合并有房颤。所有患者均有持续性室性心动过速,大多数患者发生急性心脏骤停事件。

PTB 心电诊断数据库^[15]:德国国家计量署提供的数字化心电数据库,数据来自柏林的本杰明富兰克林大学的内科。该数据库包含来自 290 名受试者的 549 条记录,其中包含有 148 例心肌梗死(简称心梗)患者的 368 条记录和 52 例正常志愿者的 80 条记录,其余为心肌炎、心律失常和心绞痛病例资料。每条记录包括 15 导联 ECG;传统 12 导联和 3 个 Frank 导联心电图向量图,采样率为 1 000 Hz。

PTB-XL2020 数据库^[4]:该数据集是通过 Schiller AG 提供的设备,在 1989 年 10 月到 1996 年 7 月期间采集的,并在 PTB 数据库的基础上进行了整理和结构化,形成了来自 18 885 名患者的 21 837 条 10 s 长的临床 12 导联 ECG 记录的大型数据集。该数据集包含了 5 类心电数据,分别为正常、传导异常、心梗、心肌肥厚和 ST-T 改变,采样率为 500 Hz。

PAF 预测挑战数据库^[16]:该数据库来自 2001 年针对自动预测阵发性房颤的开放性竞赛数据库,分为一个学习集和一个大小相等的测试集,由 100 对 30 min ECG 记录组成,每对记录都是从单个导联 24 h ECG 中获得的,采样率为 128 Hz。

3 基于 ECG 信号的人工智能在心血管疾病诊断中的应用

3.1 心律失常分类 心律失常作为最常见的心血管疾病,具有复杂性和突发性等特点,会导致心悸不适、血流动力学不稳定、心功能下降等,严重时甚至会引发卒中、心脏性猝死等。准确、快速地识别出异常心律对评估心脏的健康状况、预测心脏不良事件

的发生、挽救患者生命具有重要意义^[17-18]。近年,研究者们不断探索深度学习在自动诊断心律失常中的应用,利用深度学习方法从心电信号中提取高维特征,挖掘数据的潜在联系。斯坦福大学的 HANNUN 等^[19]成功应用 CNN 处理任意长度 ECG 时序数据。该研究利用一款贴片式单导联 ECG 监测设备记录 10 余天的模拟 II 导联 ECG,从 53 549 例患者中采集 91 232 条心电数据构建训练集,对 CNN 进行有监督特征学习,包括窦性心律、房颤/心房扑动、房室传导阻滞、房性早搏、室上性心动过速、室性心动过速等 12 种 ECG 特征。该研究的测试结果表明,在心律失常的识别与分类方面,深度学习的平均 F1 分为 0.837,优于心脏科医生(0.780),受试者工作特征曲线下面积值高达 0.97。SAKLI 等^[20]将 MIT-BIH、CPSC 2018、PTB、Fantasia 和 BIDMC 这 5 个公开数据集合并,利用残差神经网络(residual neural network, ResNet)深度学习 12 导联 ECG 信号,实现对 27 种含心电图异常及不同类型心律失常的识别与分类,准确率达 97.63%,灵敏度达 89.67%。BUI 等^[21]提出了一种基于密集连接卷积网络(densely connected convolutional network, DenseNet)的轻量级模型架构实现心律失常自动分类,在 CinC2017 和 ICBE2018 数据集上表现优异。MISHRA 等^[22]构建了 15 层 CNN,精准识别 MIT-BIH 数据库中的房性早搏、室性早搏、左束支传导阻滞、右束支传导阻滞及正常心电图。

在心律失常自动分类领域,随着深度学习技术的不断应用,研究者们开始深入地探索融合多种神经网络进行心电信号诊断以提高其准确率的可能性。杨浩等^[23]将 CNN 和多层双边长短时记忆网络(bi-directional long short-term memory network, BiLSTM)相结合,采用多输入的结构,将心电信号分隔成两种不同大小尺度的心拍(beat)信号,分别进行特征提取与合并,可较高效地自动识别正常、室性早搏、房性早搏和未分类心拍。RAHUL 等^[24]结合 6 层 CNN 和 BiLSTM,截取记录时长 5 s 的房颤、心室颤动、室性心动过速和正常心律进行学习分类。在 MIT-BIH 心律失常数据库的测试下,采用 10 折交叉验证方法,达到了 99.41% 准确率。XIA 等^[25]提出了一种结合 Transformer 模型与 CNN 的新框架,使用 CNN 从单个心搏中提取局部特征,并基于轻量级 Transformer 编码器关注相邻心搏间的全局特征。该研究依据美国医疗仪器促进协会标准的心律失常的 5 个分类(正常、室上性异位搏动、室性异位搏动、融合、未知),在 MIT-BIH 数据集上的

实验结果显示,该框架实现了 97.66% 的总体分类准确率,尤其是在处理不平衡患者间 ECG 分类时展现出卓越性能。ZHAO 等^[26]将 ResNet 在频域上的特征提取能力与时序卷积网络(temporal convolutional network, TCN)在时域分析上的能力相结合,提出 TCN-ResNet 模型。该模型在单导联心电图的房颤检测中表现出色,取得了高达 97% 的分类准确率。

3.2 心梗检测与定位 心梗发生于冠状动脉血流的急剧减少或完全阻断,心肌组织进而发生急性、不可逆的缺血性坏死,其早期识别对于临床干预效果具有决定性作用。心电图的动态演变在心梗的诊断中至关重要,然而传统的心电图分析手段受限于主观判断与经验依赖,当前医学研究正致力于应用先进的机器学习与深度学习技术,以实现心梗诊断的自动化、精准化,从而提高诊断效率与准确性,为患者提供更为及时、有效的治疗策略。

在探索机器学习用于心梗检测与定位领域的应用时,多种有监督学习的分类模型发挥了各自的优势。其中支持向量机(support vector machine, SVM)、K-最近邻(k-nearest neighbor, KNN)、决策树(decision tree, DT)等经典模型,展现出广泛的应用前景。2012 年 ARIF 等^[27]通过二元小波转换(DWT)从 12 导联 ECG 中提取 T 波、Q 波、ST 段的特征,并利用 KNN 分类器实现了心梗的准确诊断与定位。而 DOHARE 等^[28]则深入分析了电信号的多个维度,提取了包括 P 波时限、QRS 波时限、ST-T 复合间期及 QT 间期在内的 220 个特征,对来源于 PTB 数据库的 60 例心梗患者及正常对照的 12 导联 ECG 经主成分分析降维后,利用 SVM 模型进一步提升了心梗检测的效能,灵敏度、特异性、准确率均达到 96.66%。

深度学习特别是神经网络技术的应用推动了心电分类向高度自动化与智能化迈进。WANG 等^[29]创新性地将多导联集成神经网络应用于心梗检测,拟区分来源于 PTB 数据库的前壁心梗、下壁心梗和正常对照 ECG 信号,通过结合三种子网络与多导联 ECG 信号,实现了前壁和下壁心梗定位的 92% 至 97% 的高分类准确率。FENG 等^[30]则通过 CNN 与 LSTM 的结合(CNN-LSTM),充分利用了序列数据的时空特性,在心梗检测上取得了 95.40% 的准确度。XIONG 等^[31]进一步探索了 DenseNet 在 12 导联 ECG 分析中的应用,成功实现了对前壁、前侧壁、前间隔、前间隔侧、下壁、下侧壁、下后壁、下后侧壁、侧壁、后壁、后侧壁 11 个部位心梗的精确定位,分类准确度高达 99.87%。此外,STRODTHOFF 等^[32]也展

示了全连接神经网络在 PTB 数据集上对于心梗检测的出色表现,达到了 93.3% 的准确度。

为了更清楚地看到心电图的变化,研究人员开始把一维的心电图信号变成二维图像,然后用神经网络来诊断。HAO 等^[33]设计了一种多分支融合网络,以 12 导联 ECG 图像为输入,成功实现了 94.73% 的心梗检测准确率。SWAIN 等^[34]则通过改良的 Stockwell 变换与相位分布模式,进一步提升了心梗检测的准确性、灵敏度和特异性,达到了 99.93% 的效果。而 ZHANG 等^[35]利用格拉姆角场技术,将 ECG 时间序列转换为图像,并结合主成分分析网络进行特征提取,最终在心梗定位上取得了优异的性能。

4 总结与展望

综上,深度学习技术在基于 ECG 信号的心律失常分类、心梗检测与定位等方面已经取得了卓有成效的进展。尽管这些技术能够快速解读 ECG,然而仍存在一些局限性:①目前大部分网络模型所使用的训练和验证数据集过于单一,缺乏与临床数据的结合,限制了模型在泛化能力方面的表现;②现有数据集往往难以满足大规模、高质量和多样化的要求,导致深度学习模型泛化能力受限,个人的特异性差异也限制了深度学习模型在广泛人群中的泛化能力;③现有的模型主要关注提高模型分类的准确性,却忽视了深度学习模型在临床应用中的实际效果和解释性;④计算资源和训练时间的需求也限制了深度学习在心血管疾病诊断领域的广泛应用。因此,未来工作需要针对这些局限性进行深入研究,以推动深度学习在医疗领域的发展和应用。尽管如此,人工智能在心血管疾病诊断中的前景仍然令人充满期待。

参考文献

- [1] YILDIRIM O, PLAWIAK P, TAN R S, et al. Arrhythmia detection using deep convolutional neural network with long duration ECG signals[J]. *Comput Biol Med*, 2018; 102411.
- [2] WANG R, FAN J, LI Y. Deep multi-scale fusion neural network for multi-class arrhythmia detection[J]. *IEEE J Biomed Health Inform*, 2020, 24(9): 2461.
- [3] FOTIADOU E, VAN SLOUN R J G, VAN LAAR J O E H, et al. A dilated inception CNN-LSTM network for fetal heart rate estimation[J]. *Physiol Meas*, 2021, 42(4): 45007.
- [4] PRABHAKARARAO E, DANDAPAT S. Multi-scale convolutional neural network ensemble for multi-class arrhythmia classification[J]. *IEEE J Biomed Health Inform*, 2022, 26(8): 3802.
- [5] YUN D, LEE H C, JUNG C W, et al. Robust R-peak detection in an electrocardiogram with stationary wavelet transformation and separable convolution[J]. *Sci Rep*, 2022, 12(1): 19638.

- [6] POURBABAEE B, ROSHTKHARI M J, KHORASANI K. Deep convolutional neural networks and learning ECG features for screening paroxysmal atrial fibrillation patients[J]. IEEE Transactions on Systems Man, and Cybernetics Systems, 2018, 48(12):2095.
- [7] ZHANG C, WANG G, ZHAO J, et al. Patient-specific ECG classification based on recurrent neural networks and clustering technique. Proceedings of IASTED international conference on biomedical engineering, February 20-21, 2017 [C]. Innsbruck; IEEE, 2017, 2017:63.
- [8] ÜBEYLI E D. Recurrent neural networks employing Lyapunov exponents for analysis of ECG signals[J]. Expert systems with applications, 2010, 37(2):1192.
- [9] DHANANJAY B, VENKATESH N P, BHARDWAJ A, et al. Design and development of LSTM-RNN model for the prediction of RR intervals in ECG signals. Proceedings of the International e-Conference on Intelligent Systems and Signal Processing[C]. Springer Singapore, 2022.
- [10] MOODY G B, MARK R G. The impact of the MIT-BIH arrhythmia database[J]. IEEE Eng Med Biol Mag, 2001, 20(3):45.
- [11] IVAYLO C. Assessment of the performance of the adaptive thresholding algorithm for QRS detection with the use of AHA database[J]. Bioautomation, 2007, 6:27.
- [12] HALDER B, MITRA S, MITRA M. Automatic feature extraction of ECG signal based on adaptive window dependent differential histogram approach and validation with CSE database[J]. Int J Computational Systems Engineering, 2018, 4(2/3):146.
- [13] ALQUDAH A M, ALQUDAH A. Morphological based method for automated extraction and classification of ECG ST-T wave[J]. Instrumentation Mesure Métrologie, 2021, 20(1):15.
- [14] YANG J L, SUN Z Q, ZHU W W, et al. Intelligent prediction of sudden cardiac death based on multi-domain feature fusion of heart rate variability signals[J]. EURASIP J Adv Signal Process, 2023, 2023:32.
- [15] AHAMED M A, HASAN K A, MONOWAR K F, et al. ECG Heartbeat classification using ensemble of efficient machine learning approaches on imbalanced datasets. 2nd ICA-ICT, November 28-29, 2020[C]. Dhaka; IEEE, 2020.
- [16] HE J C, LIU S, FENG X J, et al. Comprehensive analysis of heart rate variability features for accurate prediction of paroxysmal atrial fibrillation[J]. Biomed Signal Process Control, 2024, 87:105489.
- [17] QUADRI R, KHANAM S. Analysing and evaluating the performance of deep-learning-based arrhythmia detection using electrocardiogram signals[J]. International Journal of Advanced Research in Computer Science, 2024, 15(2):74.
- [18] 袁成成, 刘自结, 王常青, 等. 融合残差网络与自注意力机制的心律失常分类[J]. 生物医学工程学报, 2023, 40(3):474.
- [19] HANNUN A Y, RAJPURKAR P, HAGHPANAHI M, et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network[J]. Nat Med, 2019, 25(1):65.
- [20] SAKLI N, GHABRI H, SOUFIENE B O, et al. ResNet-50 for 12-lead electrocardiogram automated diagnosis[J]. Comput Intell Neurosci, 2022, 2022:7 617551.
- [21] BUI T H, HOANG V M, PHAM M T. Automatic varied-length ECG classification using a lightweight DenseNet model [J]. Biomedl Signal Process Control, 2023, 82(4):104529.
- [22] MISHRA U, GOLCHHA P, JEGARAJ J J R, et al. An ECG based CNN model for detection of different classes of arrhythmia[J]. SN Computer Science, 2024, 5(6):661.
- [23] 杨浩, 黄茂林, 蔡志鹏, 等. 融合 CNN 和 BiLSTM 的心律失常心拍分类模型[J]. 中国生物医学工程学报, 2020, 39(6):719.
- [24] RAHUL J, SHARMA L D. Automatic cardiac arrhythmia classification based on hybrid 1-D CNN and Bi-LSTM model [J]. Biocybern Biomed Eng, 2022, 42(1):312.
- [25] XIA Y, XIONG Y, WANG K. A transformer model blended with CNN and denoising autoencoder for inter-patient ECG arrhythmia classification[J]. Biomed Signal Process Control, 2023, 86(1):105271.
- [26] ZHAO X, ZHOU R, NING L, et al. Atrial fibrillation detection with single-lead electrocardiogram based on temporal convolutional network-ResNet[J]. Sensors, 2024, 24(2):398.
- [27] ARIF M, MALAGORE I A, AFSAR F A. Detection and localization of myocardial infarction using K-nearest neighbor classifier[J]. J Med Syst, 2012, 36(1):279.
- [28] DOHARE A K, KUMAR V, KUMAR R. Detection of myocardial infarction in 12 lead ECG using support vector machine[J]. Appl Soft Comput, 2018, 64:138.
- [29] WANG H M, ZHAO W, JIA D Y, et al. Myocardial infarction detection based on multi-lead ensemble neural network [J]. Annu Int Conf IEEE Eng Med Biol Soc, 2019, 2019:2614.
- [30] FENG K, PI X, LIU H, et al. Myocardial infarction classification based on convolutional neural network and recurrent neural network[J]. Appl Sci, 2019, 9:1879.
- [31] XIONG P, XUE Y, ZHANG J, et al. Localization of myocardial infarction with multi-lead ECG based on DenseNet[J]. Comput Methods Programs Biomed, 2021, 203:106024.
- [32] STRODTHOFF N, STRODTHOFF C. Detecting and interpreting myocardial infarction using fully convolutional neural networks[J]. Physiol Meas, 2019, 40(1):015001.
- [33] HAO P, GAO X, LI Z, et al. Multi-branch fusion network for myocardial infarction screening from 12-lead ECG images[J]. Comput Methods Programs Biomed, 2020, 184:105286.
- [34] SWAIN S S, PATRA D, SINGH O Y. Automated detection of myocardial infarction in ECG using modified Stockwell transform and phase distribution pattern from time-frequency analysis[J]. Biocybern Biomed Eng, 2020, 40(3):1174.
- [35] ZHANG G, SI Y, WANG D, et al. Automated detection of myocardial infarction using a gramian angular field and principal component analysis network[J]. IEEE Access, 2019, 7:171570.

(2024-07-15 收稿)

(王晞编辑)