



基于自动机器学习的运动过程心电检测算法

宋 群¹,袁青霞²,王俊江³

(1. 西北工业大学 自动化学院,陕西 西安 710072;2. 中科锐眼(天津)科技有限公司,天津 300350;
3. 天津城建大学 体育部,天津 300384)

摘要 心电图(ECG)是一种常规的身体监测手段,通过分析人体在不同状态下心电活动的变化,评估其心血管健康状况。考虑到人体生理特征的差异,以及不同状态下心电活动规律的变化,如何设计一种自动适应各种场景的心电信号分类模型具有重要的现实意义。该文创新性地将心电信号转化为图像数据,并采用可微分神经网络架构搜索算法(PC-DARTS)对不同分布的心电检测数据自动搭建最优神经网络模型,实现了不同场景下心电信号的精准分类。分别在心律失常数据集 PhysioNet MIT-BIH 和诊断性心电图数据集 PTB 上进行心电信号分类实验,以验证所提方法在不同应用场景下的辨识性能。实验结果表明,与其他方法相比,该文算法具备更高的准确度和更强的鲁棒性,同时,能够应对不同采集设备、实验环境以及被试人群所带来的分类辨识挑战,具备较强的泛化性能。未来,该研究成果有望与新型心电监测设备相结合,实现高效精准的心电检测功能,加速心电检测在更多领域中的落地与应用。

关键词 心电检测;运动健康;神经网络;自动机器学习;神经架构搜索

中图分类号:TP181 **DOI**:10.16152/j.cnki.xdxbr.2023-05-009

Automated machine learning-based algorithm for ECG monitoring during exercise

SONG Qun¹, YUAN Qingxia², WANG Junjiang³

(1. School of Automation, Northwestern Polytechnical University, Xi'an, 710072, China;

2. Zhongke Ruiyan (Tianjin) Technology Co., Ltd., Tianjin 300350, China;

3. Department of Physical Education, Tianjin Chengjian University, Tianjin 300384, China)

Abstract Electrocardiogram (ECG) is a commonly used method for monitoring the body. The analysis of alterations in electrocardiographic activity during physical exercise can evaluate an individual's cardiovascular health status. Designing an automatic adaptive ECG signal classification model that can accommodate different physiological characteristics and changes in ECG activity patterns in different states is of great practical significance. In this study, we proposed an innovative approach that transformed ECG signals into image data and automatically constructed optimal neural network models for different distributions of ECG detection data using the differentiable neural architecture search algorithm (PC-DARTS). This approach achieved accurate ECG

收稿日期:2023-06-27

基金项目:国家自然科学基金(62006192)

第一作者:宋群,男,博士,副研究员,从事模式识别研究,songqun@nwpu.edu.cn。

通信作者:王俊江,男,副教授,从事运动科学和运动健康等研究,Feim126@126.com。

signal classification in various scenarios. In this paper, ECG signal classification experiments were conducted on the PhysioNet MIT-BIH arrhythmia dataset and the PTB diagnostic ECG dataset, respectively, to verify the discrimination performance of the proposed method in different application scenarios. The results indicate that the algorithm proposed in this paper has higher accuracy and greater robustness compared to other methods. At the same time, the proposed method is able to cope with the classification challenges posed by different acquisition devices, different experimental environments and different subject populations, and has sufficient generalization performance. In the future, the research results are expected to be combined with new ECG monitoring devices to achieve efficient and accurate ECG detection and accelerate the application of ECG detection in more fields.

Keywords electrocardiogram; sports health; neural networks; automated machine learning; neural architecture search

心脏疾病已经成为当今世界上最主要的公共卫生挑战之一,对人类的健康和生命造成了极大的威胁^[1]。随着现代生活方式的改变和人口老龄化程度的加深,心脏疾病的发病率不断攀升。因此,心脏疾病的监测变得至关重要,它可以帮助医务人员尽早发现心脏问题,及时采取干预措施,避免悲剧性后果的发生。有效的监测不仅有助于诊断心脏病症,还可以评估患者的风险因素,制定个体化的诊疗方案。因此,进行实时心电监测并对监测结果进行分析和解释,对于保障人类健康、提高全人类生活质量具有重要意义。

心电图(electrocardiogram, ECG)是记录心脏电活动的无创方法,由于其简单、低成本和高精度,已经成为心血管病诊断中最常用的工具之一^[2]。运动 ECG 技术是一种能够记录运动过程中 ECG 变化的技术,通过实时检测 ECG 信号,研究对象在物理活动条件下的心脏生理学。近年来,运动 ECG 技术得到了广泛应用,成为评估运动员运动期间心脏功能的常用工具^[3]。而随着传感器和信号处理技术的快速进步,运动 ECG 监测设备的灵敏度和特异性也得到了极大的提高,使其成为筛查运动员是否患有潜在心血管疾病的有效工具之一。在此基础上,高锦炜设计了一种基于离散小波变换(discrete wavelet transformation, DWT)的低功耗实时 ECG 信号处理器^[4]。该处理器通过使用 DWT 算法将 ECG 信号转换为时频域信号,并采用自适应阈值算法进行去噪和 R 波检测。实验结果表明,该处理器准确性高,节能效果显著,非常适合移动设备上的应用。杨宇等人探讨了基于小波变换和支持向量机(support vector machine, SVM)的 ECG 信号分类方法^[5]。该方法用小波变换将 ECG 信号转换到小波域,然

后,使用 SVM 分类器对不同类别的 ECG 信号进行分类。研究结果表明,该方法在分类准确率和鲁棒性方面表现优异。Park 等人提出了一种改进的小波变换算法 WTSEE 用于 R 波检测^[6]。该算法在常规小波变换的基础上,增加了非线性阈值控制和动态滑动窗口等优化方式,能够提高 R 波检测的准确性和稳定性。实验结果表明,该算法比传统的 R 波检测算法更具优势。朱俊江等人讨论了基于小波分析的 ECG 信号去噪方法^[7]。该方法将小波分析与滤波技术相结合,能够克服传统带通滤波器存在的较大幅度漂移和陡峭滤波器存在的过度去噪问题,效果显著。王凤提出了一种基于多尺度分析的 ECG 信号分类算法^[8]。该算法通过多尺度小波分解实现了对 ECG 信号的多层次特征提取,然后,使用基于集合经验模态分解(ensemble empirical mode decomposition, EEMD)的自适应阈值算法对不同类别的 ECG 信号进行分类。研究结果表明,该算法在分类准确率和稳定性方面都表现良好。马金伟探讨了如何使用深度学习技术对 ECG 信号进行自动分类^[9]。其提出的融合网络模型可以从 ECG 信号中学习有效的特征,并且能够实现高精度的分类,同时还可以用于检测不同类型的心脏病。Prakash 等人探讨了如何改善 ECG 信号检测中的假阳性问题^[10]。该研究采用随机森林算法对 ECG 信号进行分类和去噪,能够有效地减少假阳性率,并提高整体的诊断准确性,同时也适用于其他医学领域中的信号处理问题。孟球等人提出了一种基于卷积神经网络(convolutional neural network, CNN)的 ECG 信号分类算法^[11]。该算法具有较高的分类准确率,可以有效地区分正常和异常 ECG 信号,此外,还表现出较强的鲁棒性,适用于不同的数据

集和应用场景。吴佳全提出了一种基于双向长短时记忆网络和卷积神经网络的 ECG 信号分类算法^[12]。该算法模拟了人类心脏的生理特性,能够高效地提取和识别 ECG 信号中的特征,并且在分类准确率和稳定性方面都表现良好。孟瑶开发了一款基于移动设备的实时 ECG 信号检测系统^[13]。该系统采用低功耗计算架构和自适应阈值算法,可以实时获取、去噪和分析 ECG 信号,具有良好的性能和可靠性,适用于临床和家庭健康监测等领域。然而,由于人体生理特征和运动状态下心脏电信号变化等因素的影响,ECG 实时检测技术在精度上还有一定的提升空间。

近年来,机器学习在时序信号领域的应用备受关注,其中,ECG 信号是一个典型的例子^[14]。过去,基于物理模型的方法如差分方程和傅里叶变换等被广泛应用于处理这类信号,但需要手动提取信号特征,往往过于简化实际情况。在近年的一些研究中,一些学者通过引入机器学习算法自动提取时序信号特征,并对信号进行分类和预测。然而,目前主流的机器学习模型都是由专家进行人工设计,需要手动调整模型结构和超参数设置,导致这些模型在不同数据集中的泛化性和灵活性受到限制。为了实现模型结构和参数的自适应调整,有学者提出了新的理论,即神经网络架构搜索(neural architecture search, NAS)。该理论旨在自动化地发现合适的神经网络结构以完成特定的人工智能任务。其中, Liu 等人提出了利用梯度下降算法搜索卷积神经网络架构的高效策略 DARTS,并在 ImageNet 数据集上获得了令人瞩目的结果^[15]。Pham 等人通过强化学习训练一个控制器,从大量计算图中选择最优子图,并预测子图验证准确度,轻松构建最优神经网络结构^[16]。Chen 等人提出采用序列化的模型优化方法对更大规模的问题进行了优化^[17]。Cai 等人提出一种基于梯度的可微架构搜索算法,采用管道连接将神经网络分解为 3 个基本构建块:卷积、标准化和非线性变换^[18]。Brock 等人为每个可能的子网络赋予一个共享的向量,并使用共享的控制器搜索网络结构和权重,以支持快速、大规模的架构搜索^[19]。Shen 等人通过采用新的搜索策略,将多个搜索过程组合起来,更好地探索架构空间,并使用注意力机制关注重要部分,实现高效的架构搜索^[20]。Wu 等人采用自适应资源分配来实现高效的训练,从一个较小的“种子”网络开始,逐步迭

代并强化网络性能^[21]。Liu 等人提出一种新型的、基于进化算法的 NAS 方法,使用最小变异操作作为遗传机制,并使用多目标优化算法进行训练^[22]。Huang 等人使用 3 个模块来优化模型结构,其中一个模块负责架构搜索,另一个模块用于权重学习和更新,第 3 个模块负责共享参数^[23]。Tan 等人利用自动化设计优化神经网络、加速模型训练和推断,并在图像分类、对象检测等方面获得了较好的结果^[24]。

虽然自动机器学习方法在其他领域已经取得了显著进展,但在 ECG 信号检测领域尚未被广泛应用。因此,采用自动机器学习方法设计更具泛化能力的模型,实现更高精度的 ECG 信号检测,具有重要的研究意义。本文旨在通过自动机器学习理论,自动设计和调整模型结构,更高效地提取和分类 ECG 信号特征。

1 方法设计

针对当前 ECG 检测技术存在的瓶颈,创新性的将 ECG 时序信号转换为图像数据,并结合计算机视觉领域成功的神经网络架构搜索算法实现了针对不同类型 ECG 数据的有效分类辨识。算法流程框架如图 1 所示。




图1 算法流程框架图

Fig. 1 Algorithm flow framework diagram

1.1 ECG 信号图像

针对原始 ECG 信号,首先将其转换为 3 种不

同的图像数据,分别为格拉姆角场(gramian angular field, GAF)、递归图(recurrence plot, PR)以及马尔可夫转移场(Markov transition field, MTF)。

1.1.1 格拉姆角场

格拉姆角场^[25]是一种用于处理时间序列数据的特征提取方法,基于格拉姆矩阵和极角场的概念,将时间序列转换为图像形式,以便利用计算机视觉和图像处理领域的成熟技术进行分析。

格拉姆角场技术的基本思想是将时间序列分成多个时间段,并使用极坐标系将每个时间段转换为一个图像。在极坐标系中,每个时间点被转换为一个点,该点的半径由时间序列的幅度确定,角度由时间序列的相位确定。然后,使用格拉姆矩阵将这些图像转换为对称正定矩阵,以便使用特征向量分解等方法进行进一步分析。最后,使用基于格拉姆角场的特征向量进行分类、聚类等任务。

具体而言,给定一个长度为 n 的 ECG 时间序列 $x = \{x_1, x_2, \dots, x_n\}$, 首先,将其分为 k 个时间段 $x^{(1)}, x^{(2)}, \dots, x^{(k)}$ 。对于每个时间段,使用以下公式将其转换为极角场,

$$G(x^{(i)})_{p,q} = \frac{1}{2} \cos\left(\frac{2\pi}{\tau}(x_p^{(i)} - x_q^{(i)})\right) \tag{1}$$

式中: p 和 q 为当前时间段中的时间点; τ 为极角场的周期(通常取为 N); l 为当前子序列序号。然后,使用以下公式计算格拉姆矩阵,

$$G_{i,j} = \frac{1}{k} \sum_{l=1}^k G(x_l^{(i)}) G(x_l^{(j)}) \tag{2}$$

式中: i 和 j 为不同时间段中对应的时间点。最终,格拉姆矩阵可以看作是一个 $N \times N$ 的对称正定矩阵,其中,每个元素都是 k 个时间段中对应位置的极角场之间的相似度。

格拉姆角场的优点在于它能够很好地处理时间序列中的非线性关系,并且可以使用计算机视觉和图像处理领域的技术对其进行进一步分析。此外,格拉姆角场的计算量较小,适用于大规模数据集。因此,本节使用格拉姆角场对 ECG 信号进行特征提取。

1.1.2 递归图

递归图也称为重现性图,是一个图形化的工具,用于分析时间序列中的重复模式^[26]。其通过在时间序列上构造一个二维图像来显示序列中的周期性或混沌性。递归图现已广泛应用于各个领域,如物理学、生物学、经济学和气象学等。

递归图的构造基于嵌入定理(embedding theorem)。该定理指出,可以通过将时间序列转换为高维空间中的向量来捕捉序列中的结构信息。递归图的构造涉及计算时间序列中任意两个时间点之间的欧几里得距离,并将距离值转换为二进制 0 或 1。这样,递归图可以视为一个二维矩阵,其中行和列代表时间序列中的时间点,而单元格中的数字表示相应时间点之间的距离是否小于给定的阈值。基于 1.1.1 节的 ECG 信号定义,其递归图可通过下式进行计算,

$$R = \alpha(\lambda - \|x_p - x_q\|) \tag{3}$$

式中: λ 为阈值; α 为重边函数; p 和 q 为时间点。

递归图的图形化特征可以用于识别和分类时间序列中的不同模式,例如周期性和混沌性,因此,本节利用递归图提取 ECG 信号特征。

1.1.3 马尔可夫转移场

马尔可夫转移场是一种将时间序列转换为二维图像的方法,用于描述时间序列数据的时空结构。遵循已有方法^[25],将 ECG 信号转换为马尔可夫转移场。

在马尔可夫转移场中,首先,将 ECG 时间序列 $x = \{x_1, x_2, \dots, x_n\}$ 分成 k 个长度为 N 的子序列,然后,计算每个子序列 i 中连续两个值 j 和 f 之间的转移概率,这些概率被组合成一个 $N \times N$ 的转移矩阵。

$$P_l(j, f) = P(x_l^{(i)}(t+1) = f | x_l^{(i)}(t) = j) \tag{4}$$

式中: P 为转移概率函数; t 为当前时间点; l 为当前子序列序号; P_l 为 j 和 f 间转移概率。然后,使用这个转移矩阵来生成一个二维图像,其中,每个像素表示从一个状态到另一个状态的概率,

$$m_l(j, f) = F(P_l(j, f)) \tag{5}$$

式中: F 是一个将概率值映射到像素值的函数。将所有时间点的图像 m_l 拼接起来,即可得到当前时间序列的马尔可夫转移场。

1.1.4 ECG 信号图像

将同一段 ECG 信号的格拉姆角场、递归图以及马尔可夫转移场进行合并,得到格式类似于红绿蓝(RGB)图像的三通道 ECG 信号图像。这一图像将作为神经网络架构搜索算法的输入,实现对 ECG 信号的分类辨识。

1.2 神经网络架构搜索算法

1.2.1 搜索空间

由于 ECG 信号图像其数据结构与 RGB 图像

相似,因此,使用计算机视觉中常用的 3×3 最大池化, 3×3 的平均池化, 3×3 、 5×5 的可分离卷积, 3×3 、 5×5 的扩展卷积,直接连接和无连接作为候选操作,所有卷积核的数量被设定为 16。

1.2.2 模型架构

在将 ECG 信号图像输入模型前,首先,使用 3×3 卷积组成的根节点 1 与根节点 2 对 ECG 信号图像进行特征提取。根节点 1 与根节点 2 的输出构成模型主体的输入。模型主体由普通模块和压缩模块堆叠而成,二者使用相同的内部结构。

在模块内部,设置 4 个节点,不包括 2 个输入节点和 1 个输出节点。节点的概念继承自 PC-DARTS,它本质上代表了对网络中张量的连接操作,这些张量来自前面位置的节点或模块的输出。节点这一特殊概念的引入促进了网络结构的设计和改变。每个节点可以接收其前进方向上任何 2 个节点的输出,模块内所有节点的输出将被串联成模块的输出。

在模块的外部,网络由 2 个普通模块与 1 个压缩模块交替构建,压缩模块是一个特殊的模块,引入的目的是减少通过网络的特征图的大小,提升模型感受野。为了达到这个目的,与压缩模块的输入节点相邻的所有节点都设置步长为 2。每个模块将前面 2 个模块的输出作为输入。

在交替堆叠 2 层普通模块、1 层压缩模块和 2 层普通模块后,已经高度抽象化的特征被输入平均池化层和全连接层,得到最终的分类便是结果。

1.2.3 算法流程

为了能够针对 ECG 信号图像特征构建针对性的辨识模型,引入基于梯度的神经网络架构搜索算法,在超空间中寻找最优的模型架构。PC-DARTS 是一种基于梯度下降的架构搜索算法^[27],它的基本思想是在超图空间中搜索最优的神经网络结构,超图由节点和边组成。其中,节点表示神经网络中的隐藏层,边表示神经元之间的连接关系。在 PC-DARTS 中,每个节点可以选择不同的操作,如卷积、池化或空间变换。通过搜索最优的节点操作和连接关系,PC-DARTS 可以得到最优的神经网络结构。

具体来说,PC-DARTS 算法包括 2 个阶段。

第 1 阶段是基于弱监督的搜索阶段,通过对训练集进行小批量采样来更新神经网络结构。在每个小批量中,PC-DARTS 使用梯度下降法优化超图中的权重,同时,使用基于 Softmax 的方法更

新节点的离散操作分布。

$$f_{i,j}^{\text{PC}}(x_i; S_{i,j}) = \sum_{o \in O} \frac{\exp\{\alpha_{i,j}^o\}}{\sum_{o' \in O} \exp\{\alpha_{i,j}^{o'}\}} \cdot o(S_{i,j} \cdot x_i) + (1 - S_{i,j}) \cdot x_i \quad (6)$$

式中: x_i 代表第 i 个节点的输出; $\alpha_{i,j}^o$ 是被选中的候选操作 $o(S_{i,j} \cdot x_i)$ 的权重; $(1 - S_{i,j}) \cdot x_i$ 则表示未被采样的其他候选操作。在这个过程中,每个节点的操作都会被更新,使得每个节点都能够选择最优的操作。由于这个过程是基于梯度下降的,所以可以使用反向传播来有效地计算梯度,加速优化过程。并且采样部分通道进行更新的操作有效降低了显存占用。

为了保证采样过程中无参数操作不会占据主导地位,引入边缘归一化来平衡所有候选操作的出现概率,

$$x_j^{\text{PC}} = \sum_{i < j} \frac{\exp\{\beta_{i,j}\}}{\sum_{i' < j} \exp\{\beta_{i',j}\}} \cdot f_{i,j}(x_i) \quad (7)$$

式中: $\beta_{i,j}$ 代表了输入 x_i 的归一化权重。

第 2 阶段是基于强监督的微调阶段。在这个阶段,PC-DARTS 使用整个训练集来微调网络结构,以得到最终的神经网络模型。此时,搜索过程已经完成,PC-DARTS 将使用之前搜索得到的结构训练神经网络。在微调过程中,PC-DARTS 使用正常的反向传播更新权重,使得模型的性能最大化。

PC-DARTS 的优点在于能够自动搜索最优的神经网络结构,无需人为地指定网络的结构和超参数,还可以在较短的时间内得到最优的结果,并且具有良好的可扩展性。使用 PC-DARTS 对 ECG 信号图像进行针对性的模型搭建,对应对不同的 ECG 分类检测场景极为有效。

2 实验设置

本节介绍研究所采用的 2 个 ECG 数据集,分别是 PhysioNet MIT-BIH 心律失常数据集和 PTB 诊断性 ECG 数据集。这 2 个数据集是常用的 ECG 信号分类和心肌梗塞检测任务的基准数据集。在实验中,采用采样频率为 125 Hz 的 ECG 第二导联重采样数据作为输入,并使用 ECG Heartbeat Categorization^[28]提供的标准化形式的数据集,这些数据集已经去噪,并且训练和测试部分以标准 ECG 心跳的形式提供。在此基础上,还介绍了本研究的模型训练与优化细节。

2.1 PhysioNet MIT-BIH 心律失常数据集

PhysioNet MIT-BIH^[29] 心律失常数据集是一个常用于 ECG 信号处理研究的数据集,该数据集包含来自 MIT-BIH 心律失常数据库的 47 名被试的 ECG 记录,是一组由麻省理工学院研究者在波士顿贝斯以色列医疗中心的患者身上采集的 ECG 数据。

该数据集包含 48 个半小时的 ECG 记录,每个记录都由专家团队逐拍注释。记录使用双通道 ECG 采集设备,采样率为 360 Hz,每个样本的分辨率为 11 位。这些记录来自 47 名受试者,其中一些人患有心律失常,另一些人则身体健康。共有 109 446 个心拍被 2 名专家共同手动注释,利用这些注释,按照 AAMI EC57 标准^[30],创建了 5 个不同的心跳分类,如表 1 所示。

表 1 数据集标注与 AAMI EC57 类别之间映射关系
Tab.1 The mapping between annotations and AAMI EC57 categories

类别	标注
N	正常
	左/右束支传导阻滞
	房性逸搏
	结性逸搏
S	房性早搏
	异常性房性早搏
	结性早搏
	心房上性早搏
V	早期室性收缩
	室性逸搏
F	室性融合波
Q	起搏器波
	起搏和正常搏动融合波
	未分类

这个数据集已经被广泛应用于心律失常识别、ECG 信号分析、分类、噪声去除等方面的研究。该数据集的标准化格式和详细注释使得研究人员可以更容易地使用这些数据进行研究和比较不同算法的性能。

同时,该数据集也带有一些挑战,比如心律失常的种类和数量、ECG 信号的噪声和干扰等,使得研究人员需要使用一些高效的算法来处理这些

问题。因此,该数据集为研究 ECG 信号处理和心律失常识别提供了重要的基础和平台。

由于 PhysioNet MIT-BIH 数据集中不同类别的样本量严重失衡,且部分类别样本量过少无法支撑深度学习模型完成训练。因此,使用 SMOTE^[31]对少数类别进行上采样,最终,各个类别的样本数如表 2 所示。

表 2 PhysioNet MIT-BIH 数据集数据增强后不同类别样本量对比

Tab.2 Comparison of sample sizes of different categories after data enhancement of the PhysioNet MIT-BIH dataset

类别	原始样本量	数据增强后样本量
N	72 471	72 471
S	2 223	30 000
V	5 788	20 000
F	641	20 000
Q	6 431	10 000

2.2 PTB 诊断性 ECG 数据集

PTB 诊断性 ECG 数据集^[32]是一组经过标记的 ECG 数据,用于心脏疾病的分类和诊断。该数据集由德国基尔大学的心脏病学家 Heinrich Schiller 教授领导的团队收集和标记,旨在提供一个可靠的数据集,用于评估和比较不同的 ECG 分析算法。该数据集包含来自 549 名患者的 549 个 12 导联 ECG 记录,其中包括正常记录和各种心脏病例,如心肌缺血、心肌梗死、心肌肥厚和心律失常等。每个记录都由 ECG 机器记录,并由一名经验丰富的 ECG 技术人员进行了手动标记。标记包括了 QRS 波群、ST 段、T 波、P 波等波形的位置和形态。

研究使用的数据为其中被诊断为心肌梗死的 148 名被试的 ECG 数据,以及 52 名健康被试的数据。

2.3 训练与优化

为了验证算法的性能,本研究将 2 个数据集分别进行了划分,划分结果如表 3 所示。其中,MIT-BIH 数据集在数据集提供者的划分方式的基础上,使用 SMOTE 进行数据增强,最终选取 152 471 个样本作为训练集,21 892 个样本作为测试集。在 PTB 上,随机选取 6 400 个样本作为训练集,8 152 个样本作为测试集。

表 3 训练集与测试集样本划分

Tab. 3 The samples split of the train and test set		
数据集名称	训练集样本量	测试集样本量
PhysioNet MIT-BIH	152 471	21 892
PTB	6 400	8 152

在模型架构搜索阶段,即神经网络架构搜索算法的第 1 阶段,使用训练集中 70% 的数据进行模型架构迭代,剩余的 30% 用于模型权重训练。

表 4 模型超参数设定

Tab. 4 The hyperparameter setting of the model		
训练超参数	PhysioNet MIT-BIH(第 1 阶段/第 2 阶段)	PTB(第 1 阶段/第 2 阶段)
批次大小	16/64	16/32
drop 概率	0.35/0.25	0.35/0.25
初始通道数	8/8	8/8
模块堆叠数	5/5	5/5
学习率	0.001/0.001	0.001/0.001
权重衰减	0.001/0.001	0.001/0.001
训练 epoch 数	50/50	50/50
动量	0.99/0.99	0.99/0.99

对于 PhysioNet MIT-BIH 心律失常数据集,在模型架构搜索阶段设定批次大小为 16,drop 概率为 0.35,初始通道数为 8,模块堆叠数为 5,学习率为 0.001,权重衰减为 0.001,训练 epoch 数为 50。在再训练阶段,将批次大小设定为 64,drop 概率改为 0.25,其余超参数保持不变。

对于 PTB 数据集,在模型架构搜索阶段设定批次大小为 16,drop 概率为 0.35,初始通道数为 8,模块堆叠数为 5,学习率为 0.001,权重衰减为 0.001,训练 epoch 数为 50。在再训练阶段,将批次大小设定为 32,drop 概率改为 0.25,其余超参数保持不变。对于 2 个数据集,均采用动量为 0.99 的 Adam 优化器进行优化。

本研究所提出的方法在 PyTorch 中实现,基于 AMD CPU (R9-3950X, 3.5 GHz) 和 NVIDIA GPU (RTX 3090)。

3 实验结果分析

本节将展示在 PhysioNet MIT-BIH 和 PTB 数据集上的神经架构搜索结果,并将分类辨识精度与其他先进算法进行对比,以证明本研究算法的泛化性与鲁棒性。

3.1 PhysioNet MIT-BIH 数据集分类结果

网络架构搜索算法在 PhysioNet MIT-BIH 数据集上搜索得到的模型最终架构如图 2 所示,其

在再训练阶段,即神经网络架构搜索算法的第 2 阶段,使用训练集中的全部数据对架构固定的模型进行权重再训练。

在将数据送入神经架构搜索算法前,首先,将 ECG 图像大小调整为 227×227 。对 2 个不同的数据集分别选取不同的超参数,以保证模型具有较高的辨识分类精度,如表 4 所示。

中,内部连接结构和候选操作选择在表 5 中展示。在图 2 中,压缩模块从模块 k 和 $k-1$ 引出的连线表示步长为 2 的操作,这些操作进一步压缩了特征图大小,提高了模型的感受野。从搜索结果中可以看出,在普通模块中,模型倾向于选择扩张卷积和压缩卷积来提取输入的局部特征。而在压缩模块中,模型更倾向于选择平均池化和最大池化来获取输入的全局特征,这一现象也符合模型最初的设计理念。




图 2 网络架构搜索在 PhysioNet MIT-BIH 数据集上的结果

Fig. 2 Result of the neural architecture search on the PhysioNet MIT-BIH dataset

表 5 在 PhysioNet MIT-BIH 数据集上搜索得到的网络架构参数

Tab. 5 The network architecture parameters obtained through searching on the PhysioNet MIT-BIH dataset

模块名称	节点	输入节点	操作
普通模块	节点 1	模块 $k-2$, 模块 $k-1$	3×3 最大池化, 3×3 扩张卷积
	节点 2	模块 $k-1$, 节点 1	3×3 扩张卷积, 3×3 扩张卷积
	节点 3	模块 $k-2$, 模块 $k-1$	直接连接, 3×3 扩张卷积
	节点 4	节点 1, 节点 2	3×3 扩张卷积, 5×5 扩张卷积
压缩模块	节点 1	模块 $k-2$, 模块 $k-1$	5×5 可分离卷积, 3×3 可分离卷积
	节点 2	模块 $k-2$, 节点 1	3×3 最大池化, 3×3 平均池化
	节点 3	节点 1, 节点 2	3×3 最大池化, 5×5 可分离卷积
	节点 4	节点 2, 节点 3	直接连接, 3×3 最大池化

表 6 展示了本研究所提出的模型和其他先进模型的分类识别效果。可以看出,本研究的模型以 98.7% 的平均分类准确率明显优于绝大多数的对比算法。

表 6 在 PhysioNet MIT-BIH 数据集上的分类辨识结果
Tab. 6 Discrimination results on the PhysioNet MIT-BIH dataset

算法研究者	平均准确率/%
Kachuee 等人 ^[33]	93.4
Acharya 等人 ^[34]	93.5
Martis 等人 ^[35]	93.8
Li 等人 ^[36]	94.6
Ganguly 等人 ^[37]	97.3
Pham 等人 ^[38]	98.5
本课题人员	98.7

此外,本研究利用网络架构搜索技术,避免了模型架构设计的过程,大幅缩短了模型的部署时间,能够有效应对更多的应用场景,并且具有更高的分类识别精度。因此,在与 Pham 等人模型^[38]进行比较时,本研究具有一定的优势。

3.2 PTB 数据集分类结果

图 3 展示了在 PTB 数据集上进行的架构搜索结果,其中,内部连接结构和候选操作选择在表

7 中展示。与 PhysioNet MIT-BIH 数据集不同,PTB 数据集上的普通模块和压缩模块都包含了大量的卷积操作,而压缩模块中池化操作的使用频率明显降低。这可能是由于 PTB 数据集中样本数量和样本类别相对较少,模型只需提取局部特征就可以获得足够的分类准确度。




图 3 网络架构搜索在 PTB 数据集上的结果

Fig. 3 Result of the neural architecture search on the PTB dataset

表 7 在 PTB 数据集上搜索得到的网络架构参数

Tab. 7 The network architecture parameters obtained through searching on the PTB dataset

模块名称	节点	输入节点	操作
普通模块	节点 1	模块 $k-2$, 模块 $k-1$	5×5 可分离卷积, 3×3 可分离卷积
	节点 2	模块 $k-2$, 节点 1	直接连接, 5×5 扩张卷积
	节点 3	模块 $k-2$, 节点 2	3×3 可分离卷积, 3×3 平均池化
	节点 4	节点 1, 节点 3	3×3 扩张卷积, 3×3 可分离卷积
压缩模块	节点 1	模块 $k-2$, 模块 $k-1$	直接连接, 5×5 可分离卷积
	节点 2	模块 $k-2$, 模块 $k-1$	3×3 扩张卷积, 5×5 扩张卷积
	节点 3	模块 $k-2$, 节点 1	5×5 可分离卷积, 3×3 扩张卷积
	节点 4	模块 $k-2$, 模块 $k-1$	直接连接, 3×3 最大池化

在表8中与其他先进算法进行比较,本研究的模型在PTB数据集上具有最优秀的分类准确度。此外,本研究的模型具有无需手动调整架构的优点。综上所述,本研究所设计的算法有足够的泛化能力,可以应对不同的ECG识别场景,并具有广泛的应用前景。

表8 在PTB数据集上的分类辨识结果
Tab.8 Discrimination results on the PTB dataset

算法研究者	平均准确率/%
Kachuee 等人 ^[33]	95.9
Acharya 等人 ^[34]	93.5
Safdarian 等人 ^[39]	94.7
Kojuri 等人 ^[40]	95.6
Liu 等人 ^[41]	94.4
Sharma 等人 ^[42]	96.0
Pham 等人 ^[38]	98.3
本课题人员	99.0

4 结语

本研究设计基于自动机器学习的心电检测算法,有效降低了在不同应用场景下网络结构设计所需要的人工时间与成本,提升了网络架构的可解释性,为心电信号分类任务提供可靠的数据支撑和新的技术途径。将心电时序信号转换为图像的操作进一步提取了心电信号的抽象特征,提升了心电辨识准确性。所设计的模型在PhysioNet MIT-BIH 心律失常数据集和PTB诊断性ECG数据集上,分别取得了98.7%和99.0%的分类辨识精度,其性能优于以往的最优算法,且在实际应用场景中具备更强的自适应能力,未来将进一步在运动健康领域开展落地应用。

参考文献

[1] 郭航远.我国心脏康复的困境与对策[J].中国全科医学,2019,22(12):1381-1384.
GUO H Y. Difficulties and countermeasures of cardiac rehabilitation in China[J]. Chinese General Practice, 2019,22(12):1381-1384.

[2] 张和君,张跃,周炳坤.远程心电监护软件系统的设计与实现[J].计算机工程与应用,2006,42(15):219-224.
ZHANG H J, ZHANG Y, ZHOU B K. Design and implementation of software system for remote electrocardiographic monitoring[J]. Computer Engineering and Applications, 2006,42(15):219-224.

[3] 雷靳灿,廖彦剑,郑小林,等.模块式多功能运动心电检测系统的设计[J].仪器仪表学报,2010,31(7):1484-1489.
LEI J C, LIAO Y J, ZHENG X L, et al. Design of modular and multi-function exercise ECG diagnosis system[J]. Chinese Journal of Scientific Instrument, 2010,31(7):1484-1489.

[4] 高锦炜.面向离散小波变换的处理器低功耗技术研究[D].杭州:浙江大学,2015.

[5] 杨宇,司玉娟,宋晓洋.基于小波变换和支持向量机的心电信号ST段分类[J].吉林大学学报(信息科学版),2016,34(3):315-319.
YANG Y, SI Y J, SONG X Y. ST segment classification of ECG signals based on wavelet transform and support vector machine[J]. Journal of Jilin University (Information Science Edition), 2016, 34(3):315-319.

[6] PARK J S, LEE S W, PARK U. R peak detection method using wavelet transform and modified Shannon energy envelope[J]. Journal of Healthcare Engineering, 2017,2017:1-4.

[7] 朱俊江,张远辉.面向心电信号去噪的正交小波构造方法[J].中国生物医学工程学报,2017,36(1):109-113.
ZHU J J, ZHANG Y H. Construction of orthogonal wavelet for ECG signal processing[J]. Chinese Journal of Biomedical Engineering, 2017, 36(1):109-113.

[8] 王凤.心电数据的预处理与分类算法研究[D].太原:中北大学,2018.

[9] 马金伟.基于深度学习的心电信号识别分类算法研究[D].重庆:重庆理工大学,2019.

[10] PRAKASH A J, ARI S. AAMI standard cardiac arrhythmia detection with random forest using mixed features[C]//2019 IEEE 16th India Council International Conference (INDICON). Rajkot:IEEE, 2020:1-4.

[11] 孟球,葛康,宋阳,等. TSCNN:面向可穿戴心电信号监测与分析的卷积神经网络[J].中国图象图形学报,2020,25(10):2281-2292.
MENG L, GE K, SONG Y, et al. TSCNN: A convolutional neural network for the monitoring and analysis of the electrical signals of the heart from wearable devices[J]. Journal of Image and Graphics, 2020, 25(10):2281-2292.

[12] 吴佳全.基于神经网络的ECG分类算法及高能效架构研究[D].杭州:浙江大学,2020.

[13] 孟瑶.基于可穿戴传感器的实时心电检测方法研究

- [J]. 信息技术与网络安全, 2021, 40(4): 75-79.
- MENG Y. Study of real-time electrocardiogram detection based on wearable sensors[J]. Cyber Security and Data Governance, 2021, 40(4): 75-79.
- [14] 汪成亮, 宋军, 胡炳权, 等. 智能神经网络在时序信号预测上的应用[J]. 重庆大学学报(自然科学版), 2003, 26(1): 34-37.
- WANG C L, SONG J, HU B Q, et al. Application of intelligent neural network on prediction of time series signal[J]. Journal of Chongqing University, 2003, 26(1): 34-37.
- [15] LIU H X, SIMONYAN K, YANG Y M. DARTS: Differentiable architecture search [EB/OL]. (2019-04-23) [2023-03-25]. <https://arxiv.org/abs/1806.09055>.
- [16] PHAM H, GUAN M Y, ZOPH B, et al. Efficient neural architecture search via parameters sharing [EB/OL]. (2018-02-12) [2023-03-25]. <https://arxiv.org/abs/1802.03268>.
- [17] CHEN X, XIE L X, WU J, et al. Progressive differentiable architecture search: Bridging the depth gap between search and evaluation [C] // 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul: IEEE, 2020: 1294-1303.
- [18] CAI H, ZHU L G, HAN S. ProxylessNAS: Direct neural architecture search on target task and hardware [EB/OL]. (2019-02-23) [2023-03-25]. <https://arxiv.org/abs/1812.00332>.
- [19] BROCK A, LIM T, RITCHIE J M, et al. SMASH: One-shot model architecture search through HyperNetworks [EB/OL]. (2017-08-17) [2023-03-25]. <https://arxiv.org/abs/1708.05344>.
- [20] SHEN B L, XIAO A Q, TIAN J, et al. PP-NAS: Searching for plug-and-play blocks on convolutional neural network [C] // 2021 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW). Montreal: IEEE, 2021: 365-372.
- [21] WU B C, DAI X L, ZHANG P Z, et al. FBNet: Hardware-aware efficient ConvNet design via differentiable neural architecture search [C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach: IEEE, 2020: 10734-10742.
- [22] LIU H X, SIMONYAN K, VINYALS O, et al. Hierarchical representations for efficient architecture search [EB/OL]. (2018-08-22) [2023-03-25]. <https://arxiv.org/abs/1711.00436>.
- [23] HUANG S Y, CHU W T. Ponas: Progressive one-shot neural architecture search for very efficient deployment [C] // 2021 International Joint Conference on Neural Networks (IJCNN). Shenzhen: IEEE, 2021: 1-9.
- [24] TAN M X, PANG R M, LE Q V. EfficientDet: Scalable and efficient object detection [C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2020: 10778-10787.
- [25] WANG Z G, OATES T. Encoding time series as images for visual inspection and classification using tiled convolutional neural networks [C] // Workshops at the Twenty-Ninth AAAI Conference on Artificial Intelligence. Austin: AAAI, 2015: 40-46.
- [26] ECKMANN J P, KAMPHORST S O, RUELLE D. Recurrence plots of dynamical systems [J]. Europhysics Letters (EPL), 1987, 4(9): 973-977.
- [27] XU Y H, XIE L X, ZHANG X P, et al. PC-DARTS: Partial channel connections for memory-efficient architecture search [EB/OL]. (2020-04-07) [2023-03-25]. <https://arxiv.org/abs/1907.05737>.
- [28] SHAYAN F. ECG heartbeat categorization dataset [DB/OL]. (2018-05-31) [2023-03-05]. <https://www.kaggle.com/shayanfazeli/heartbeat>.
- [29] GOLDBERGER A L, AMARAL L A, GLASS L, et al. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals [J]. Circulation, 2000, 101(23): E215-E220.
- [30] AAMI. Testing and reporting performance results of cardiac rhythm and ST segment measurement algorithms: AAMI EC57[S]. Arlington: AAMI, 2012.
- [31] CHAWLA N V, BOWYER K W, HALL L O, et al. SMOTE: Synthetic minority over-sampling technique [J]. Journal of Artificial Intelligence Research, 2002, 16: 321-357.
- [32] BOUSSELJOT R, KREISELER D, SCHNABEL A. Nutzung der EKG-signaldatenbank CARDIODAT der PTB über das internet [J]. Biomedizinische Technik, 1995, 40(s1): 317-318.
- [33] KACHUEE M, FAZELI S, SARRAFZADEH M. ECG heartbeat classification: A deep transferable representation [C] // 2018 IEEE International Conference on Healthcare Informatics (ICHI). New York: IEEE, 2018: 443-444.
- [34] ACHARYA U R, OH S L, HAGIWARA Y, et al. A deep convolutional neural network model to classify heartbeats [J]. Computers in Biology and Medicine, 2017, 89: 389-396.
- [35] MARTIS R J, ACHARYA U R, LIM C M, et al. Ap-

plication of higher order cumulant features for cardiac health diagnosis using ECG signals [J]. International Journal of Neural Systems,2013, 23(4):1350014.

[36] LI T Y, ZHOU M. ECG classification using wavelet packet entropy and random forests [J]. Entropy, 2016, 18(8):285.

[37] GANGULY B, GHOSAL A, DAS A, et al. Automated detection and classification of arrhythmia from ECG signals using feature-induced long short-term memory network [J]. IEEE Sensors Letters, 2020, 4(8):1-4.

[38] PHAM B T, LE P T, TAI T C, et al. Electrocardiogram heartbeat classification for arrhythmias and myocardial Infarction [J]. Sensors, 2023, 23(6):2993.

[39] SAFDARIAN N, DABANLOO N J, AtTARODI G. A new pattern recognition method for detection and localization of myocardial infarction using T-wave integral and total integral as extracted features from one cycle of ECG signal [J]. Journal of Biomedical Science and Engineering, 2014, 7(10):818-824.

[40] KOJURI J, BOOSTANI R, DEHGhani P, et al. Prediction of acute myocardial infarction with artificial neural networks in patients with nondiagnostic electrocardiogram [J]. Journal of Cardiovascular Disease Research, 2015, 6(2):51-59.

[41] LIU B, LIU J, WANG G Q, et al. A novel electrocardiogram parameterization algorithm and its application in myocardial infarction detection [J]. Computers in Biology and Medicine,2015, 61:178-184.

[42] SHARMA L N, TRIPATHY R K, DANDAPAT S. Multiscale energy and eigenspace approach to detection and localization of myocardial infarction [J]. IEEE Transactions on Biomedical Engineering, 2015, 62(7):1827-1837.

(编 辑 李 静)