

doi:10.13682/j.issn.2095-6533.2026.05.013

基于脉搏信号的自适应三维重构 高血压识别方法

范琳^{1,2,3}, 白若昱¹

(1. 西安邮电大学 计算机学院, 陕西 西安 710121; 2. 西安邮电大学 陕西省网络数据分析与智能处理重点实验室, 陕西 西安 710121;
3. 西安邮电大学 西安市大数据与智能计算重点实验室, 陕西 西安 710121)

摘要: 针对传统脉搏诊断方法难以同步捕捉多通道特征与跨周期动态变化的问题, 提出一种基于脉搏信号的自适应三维重构(Adaptive Three-Dimensional Reconstruction, A3DR)高血压识别方法。该方法首先通过滑动窗截取多周期样本, 利用快速傅里叶变换将每个通道信号分解为多个频段, 选取能量占比最高的前 k 个频段重构“通道 $\times$ 周期 $\times$ 时序”三维特征张量。然后设计多分支并联三维卷积网络, 融合通道注意力机制, 通过三维卷积模块捕获周期内局部特征, 并同步构建周期间与通道间的全局动态依赖。最后, 将融合后的多尺度脉搏特征用于高血压识别, 实现健康人群与高血压人群的分类。在自建左右手“寸”“关”“尺”六通道脉搏数据集上的实验结果表明, 与长短期记忆网络和一维卷积神经网络相比, 所提方法准确率分别提升 7.17% 和 4.84%, 有效提高了分类准确率。

关键词: 六通道脉搏信号; 自适应三维重构; 三维特征张量; 多分支并联三维卷积网络; 通道注意力

中图分类号: TP391

文献标志码: A

文章编号: 2095-6533(2026)05-0137-10

Hypertension identification method based on adaptive three-dimensional reconstruction of pulse signal

FAN Lin^{1,2,3}, BAI Ruoyu¹

(1. School of Computer Science, Xi'an University of Posts and Telecommunications, Xi'an 710121, China;
2. Shaanxi Key Laboratory of Network Data Analysis and Intelligent Processing, Xi'an University of Posts
and Telecommunications, Xi'an 710121, China; 3. Xi'an Key Laboratory of Big Data and Intelligent
Computing, Xi'an University of Posts and Telecommunications, Xi'an 710121, China)

Abstract: Aiming at the problem that traditional pulse diagnosis methods can hardly simultaneously capture multi-channel features and cross-cycle dynamic changes, an adaptive three-dimensional reconstruction (A3DR) hypertension identification method based on pulse signals is proposed. Multi-cycle samples are intercepted by a sliding window, and each channel signal is decomposed into multiple frequency bands through the fast Fourier transform. The top k frequency components with the highest energy proportions are selected to reconstruct a three-dimensional feature tensor of “channel $\times$ cycle $\times$ time series”. A multi-branch parallel 3D convolutional network integrated with channel attention is then designed to capture local intra-cycle features and global dependencies across cycles and channels. Finally, the fused multi-scale pulse features are used for hypertension identification to distinguish healthy subjects from hypertensive subjects. A six-channel pulse dataset of “cun”, “guan”, “chi” on the left and right hands is constructed,

收稿日期: 2025-03-17

基金项目: 陕西省自然科学基金基础研究计划重点项目(2024JC-ZDXM-37); 教育部人文社会科学规划基金项目(25YJAZH035); 陕西省社会发展项目(2023-YBSF-434); 陕西省秦创原“科学家+工程师”队伍建设项目(2023KXJ-241)

引文格式: 范琳, 白若昱. 基于脉搏信号的自适应三维重构高血压识别方法[J]. 西安邮电大学学报, 2026, 31(5): 137-146.

FAN Lin, BAI Ruoyu. Hypertension identification method based on adaptive three-dimensional reconstruction of pulse signal[J]. Journal of Xi'an University of Posts and Telecommunications, 2026, 31(5): 137-146.

on dataset of which experiments show that, compared with long short-term memory and one-dimensional convolutional neural networks, the proposed method improves accuracy by 7.17% and 4.84%, respectively, which effectively improves the classification accuracy.

Keywords: six-channel pulse signal; adaptive three-dimensional reconstruction; three-dimensional feature tensor; multi-branch parallel three-dimensional convolutional network; channel attention

脉搏疾病诊断作为传统中医“四诊法”中的重要手段之一,不断得到系统性发展与沉淀^[1]。脉诊可以在无创环境下了解病人身体的内在变化,提出针对性的治疗方案^[2-5]。在现代生理学中,脉搏是一种准周期生理信号,蕴含着丰富的人体生理和病理信息。例如,当人体患有冠心病、糖尿病、动脉硬化及室性心动过速等疾病时,会导致其动脉血管顺应性降低及血液循环系统压力增加,使得患者脉搏表现出与健康人群不同的搏动特性^[6-7]。近年来,得益于计算机技术的辅助^[8-9],研究者结合中医脉诊的脉案,对脉搏信号进行数字化采集和分析,从而推动了脉搏临床诊断的科学化、客观化进程^[10-11]。

现有脉搏疾病识别方法可分为单周期特征挖掘和多周期关联特征挖掘。单周期特征挖掘旨在从每个周期内提取局部特征。例如,Martis等^[12]利用离散小波变换分解心电图信号提取周期内特征,通过线性判别分析和主成分分析实现特征降维与分类。但这种方法仅关注周期内局部信息,缺乏对信号整体趋势及周期间动态变化的建模能力。多周期关联特征挖掘通过分析周期间的相关性,捕捉信号的整体趋势和长时依赖性,更适用于动态变化的信号,尤其在诊断心律不齐等涉及长时段波动的疾病时具有显著优势。Cui等^[13]基于心电图信号分析不同周期之间的相关性变化以检测心律失常,利用长时依赖性和周期间的关联信息提升模型分类性能。Fan等^[14]利用脉搏周期间图特征进行疾病识别,通过滑动窗口截取多个连续脉搏周期,将每个窗口内的不同周期视为节点,节点间的相关度作为边,构建图特征以捕捉周期间的相关性和差异性。但图结构的构建及特征提取过程较为复杂,尤其在处理大量周期时的计算开销较大。上述研究表明,单周期特征挖掘虽能高效捕捉局部细节,具有较高的计算效率,却忽略全局变化趋势^[15-16];多周期关联特征挖掘虽能建模全局变化趋势和长时依赖,却无法体现周期内的动态变化。然而,脉搏信号不仅在全天长时序列中呈现周期模式,而且在局部短时区间内也存在明显的动态变化^[17-18],现有研究未能完整融合脉搏周期内与周期间的动态关

联,导致疾病识别准确度受限^[19]。

随着脉诊客观化研究的深入,多项研究采用多传感器同步采集“寸”“关”“尺”脉位信号并结合机器学习实现疾病识别。如Fan等^[20]提出一种多通道时空图特征的脉搏疾病识别方法,首先优选出与高血压疾病相关的通道,对优选通道进行去噪和周期分割,然后采用格拉姆角场、马尔可夫变迁场和递归图将信号转换到高维空间,进而构建通道间的相关图特征,以提高疾病识别精度,多通道信号的疾病诊断效果显著优于单通道。因此,针对传统脉搏诊断方法难以同步捕捉多通道特征与跨周期动态变化的问题,提出一种基于脉搏信号的自适应三维重构(Adaptive Three-Dimensional Reconstruction, A3DR)高血压识别方法。首先,通过快速傅里叶变换(Fast Fourier Transform, FFT)将多通道脉搏信号序列从时间域变换至频域并分解为多个频段,选取前 k 个主频重构“通道 $\times$ 周期 $\times$ 时序”三维(Three-Dimensional, 3D)特征张量,分析脉搏信号序列的周期动态变化模式。然后,设计多分支并联3D卷积模块分别处理不同周期模式的3D脉搏张量,并对多尺度脉搏特征进行自适应聚合,结合通道注意力机制捕获不同脉位通道之间的依赖关系。最后,通过全连接网络对聚合特征进行分析,实现正常人群与高血压人群的分类识别。

1 脉搏信号自适应三维重构

脉搏疾病识别通常包括多通道脉搏信号采集、信号预处理、特征提取和疾病分类识别共4个环节,识别框架如图1所示。多通道脉搏采样设备同步采集受试者左右手“寸”“关”“尺”6个脉位的脉搏信号,采集信号经放大与A/D转换后传输至上位机,并通过去基线漂移、去噪和滤波获得标准化多通道脉搏序列。特征提取环节则需要同时刻画周期内局部变化、周期间动态关联和通道间相关性。A3DR高血压识别方法基于脉搏疾病识别框架,将脉搏信号频域分解、脉搏信号自适应3D重构、3D脉搏信号特征挖掘和高血压分类识别4个

部分有机衔接,以实现健康人群与高血压人群的准确区分。




图 1 脉搏疾病识别框架

1.1 脉搏信号频域分解

通过滑动窗同步截取脉搏信号,窗长覆盖多个脉搏周期。对每个通道信号进行 FFT,将其从时域变换至频域分解为多个频段,并选取频率最高的前 k 个频段用于后续研究。FFT 通过将信号分解为不同频率的正弦和余弦分量的线性组合,实现时域信号到频域的转换^[21]。

对于长度为 L 的时域信号 $x(l)$,其频域表示为

$$X(k) = \sum_{l=0}^{L-1} x(l)e^{-j\frac{2\pi kl}{L}}, k = 0, 1, \dots, L-1 \quad (1)$$

FFT 将序列分解为偶数和奇数子序列分别计算,最终合并得到完整频谱。FFT 的优势在于其高效性和频域全局分析能力,尤其适用于脉搏信号的周期

性特征挖掘。通过 FFT 与后续处理的结合,可有效提取脉搏信号的频域特征,为疾病识别提供重要依据^[22]。

1.2 脉搏信号自适应 3D 重构

由于脉搏信号的波形变化具备准周期性且随时间不断变化,因此,各数据点在不同周期之间存在一定的模式相关性,同时在局部区间内表现出差异性^[23]。为捕获脉搏信号在相邻时间点的连续变化及在周期间的动态变化趋势,将前 k 个频段的多通道脉搏分量重构为“通道×周期×时序”3D 脉搏张量,通过分析多通道间的相关性,挖掘信号在多尺度周期间的模式变化规律,从而提升高血压诊断模型的分类精度。“通道×周期×时序”3D 脉搏张量重构过程如图 2 所示。




图 2 “通道×周期×时序”3D 脉搏张量重构过程

预处理后的二维(Two-Dimensional, 2D)多通道脉搏信号记为 $X_{2D} \in \mathbb{R}^{C \times T}$,其中 C 为通道数量, T 为单通道信号的时间长度。采用 FFT 对多通道脉搏信号 X_{2D} 进行频域分析^[24]。需要指出的是,经

FFT 后的频谱中,能量最大的频率成分通常对应信号的基频,能够反映脉搏跳动的基本频率。

对 FFT 后的脉搏张量计算各频点的振幅,所得振幅为

$$A = \text{Avg}(\text{Amp}(F(X_{2D}))) \quad (2)$$

式中: $\text{Avg}(\cdot)$ 表示所有通道振幅均值计算; $\text{Amp}(\cdot)$ 表示取幅值操作; $F(\cdot)$ 表示傅里叶变换。

考虑到脉搏信号数据在频域上存在稀疏性,即信号的大部分能量集中在相对较少的频率成分上,且为了避免无意义的高频成分引入噪声干扰,仅选择前 k 个频率作为多通道脉搏张量重构的重要参数^[25]。由此得到频率列表为

$$\{f_1, f_2, \dots, f_k\} = \arg \max_{f \in [1, T/2]} K \quad (3)$$

式中: $K(\cdot)$ 表示选取前 k 个幅值最大的频率对应的频率值 $\{f_1, f_2, \dots, f_k\}$ 。由于傅里叶变换的共轭对称性,所以仅考虑区间 $[1, T/2]$ 内的频率。

获取频率列表后,即可得到脉搏张量重构所用的周期长度列表。基于第 i 个频段计算的周期长度为

$$P_i = \frac{T}{f_i}, i \in [1, k] \quad (4)$$

考虑到频率与重构周期长度均为整型数据,在脉搏张量重构前,将对无法实现整型运算的频率值取临近值处理,使其能够被 T 整除。

基于频率列表 $\{f_1, f_2, \dots, f_k\}$ 与重构周期长度

列表 $\{P_1, P_2, \dots, P_k\}$, 可将多通道 2D 脉搏张量重构为周期数不同的多通道-多周期 3D 脉搏张量序列 $\{X_{3D}^1, X_{3D}^2, \dots, X_{3D}^k\}$, 具体表示为

$$X_{3D}^i = R_{(f_i, P_i)}(X_{2D}), i \in [1, k] \quad (5)$$

式中: $X_{3D}^i \in \mathbb{R}^{C \times P_i \times f_i}$; $R_{(f_i, P_i)}$ 表示将每个脉位通道的振动幅度值序列 X_{2D} 重构为 (f_i, P_i) 的形态表征。

重构后的多通道-多周期 3D 脉搏张量在结构上具有 3 类表征,即相邻时间点表征(周期内变化)、相邻周期表征(周期间变化)及通道间表征。因此,可通过 3D 卷积操作对该张量进行学习,提取周期内、周期间及通道间的脉搏变化模式。

1.3 3D 脉搏信号特征挖掘

为了挖掘左右手“寸”“关”“尺”不同通道间脉搏信号的相关性、脉搏周期间的关联关系及脉搏周期内的时序特征,基于重构周期长度不同的多通道-多周期 3D 脉搏张量序列 $\{X_{3D}^1, X_{3D}^2, \dots, X_{3D}^k\}$, 采用多分支并联 3D 卷积模块实现脉搏信号的自适应挖掘。该模块首先将各 3D 张量分别重构为对应的 2D 特征张量,然后通过特征自适应聚合对多通道脉搏信号蕴含的多尺度特征进行学习与整合。3D 脉搏信号自适应挖掘过程如图 3 所示。




图3 3D 脉搏信号自适应挖掘过程

针对周期数不同的 3D 重构张量序列,多分支并联 3D 卷积模块 $I_{3D}(\cdot)$ 利用尺寸不同的 3D 卷积核对周期长度不同的 3D 脉搏张量进行并行处理(每个分支包含多个并行的 3D 卷积核)。每个 3D 卷积分支可视为一个脉搏特征学习通道,第 i 个频段运算后捕捉到的 3D 特征张量为

$$X_{3D}^{i'} = I_{3D}(X_{3D}^i), i \in [1, k] \quad (6)$$

将不同学习通道下获取的特征重构为尺度相

同的 2D 脉搏特征张量序列 $\{X_{2D}^{1'}, X_{2D}^{2'}, \dots, X_{2D}^{k'}\}$ 并对其进行自适应聚合^[26], 实现脉搏信号的多尺度特征联动,从而提升模型对高血压识别的准确性。将第 i 个频段 3D 脉搏特征张量 $X_{3D}^{i'}$ 重构为 $C \times T$ 大小的 2D 张量表示为

$$X_{2D}^{i'} = R_{C,T}(X_{3D}^{i'}), i \in [1, k] \quad (7)$$

式中: $R_{C,T}(\cdot)$ 表示将第 i 个 3D 脉搏特征张量 $X_{3D}^{i'}$ 重构为 $C \times T$ 大小的 2D 张量 $X_{2D}^{i'}$, 以便后续的特征

自适应聚合处理。

聚合后的 2D 脉搏特征张量为

$$X'_{2D} = \sum W_i \cdot X^{i'}_{2D}, i \in [1, k]$$
 (8)

其中,

$$W_i = \text{Loca}(\text{Avg}_C \text{Abs}(F(X_{2D}))), i \in [1, k]。$$

式中: W_i 表示自适应系数; $\text{Loca}(\cdot)$ 表示取对应索引处的幅度均值结果; Avg_C 表示沿通道 C 进行均值处理; $\text{Abs}(\cdot)$ 表示取绝对值运算。

在上述处理过程中,自适应系数 W_i 的计算依托于式(2)傅里叶变换后的频谱 $F(X_{2D})$ 及所获取的频率列表 $\{f_1, f_2, \dots, f_n\}$ 。具体而言,首先对频谱取绝对值,消除脉搏信号的相位信息,仅保留幅度信息,便于后续聚合时更准确地捕捉主要特征。然后,沿通道维度对取绝对值后得到的 2D 幅度矩阵进行均值处理。最后,基于频率列表 $\{f_1, f_2, \dots, f_n\}$ 将各频率对应位置上的幅度均值作为自适应系数。这一方式能够增强基于关键频率成分的脉搏特征学习效果,提升对脉搏信号特征提取与分析的准确性。

在自适应聚合操作之后,进一步引入挤压-激励(Squeeze-and-Excitation, SE)通道注意力机制^[27],以增强关键通道的表征能力。对于经过自适应聚合后的特征张量 $X^{i'}_{2D}$,首先通过全局平均池化将其空间维度压缩,将每个通道的空间信息进行整合,得到每个通道的全局特征描述,记为 $G(X^{i'}_{2D})$ 。接着,将 $G(X^{i'}_{2D})$ 输入到两层全连接层中学习通道间的依赖关系。设 $V_1 \in \mathbb{R}^{C/r \times C}$ 和 $V_2 \in \mathbb{R}^{C \times C/r}$ 分别为两层全连接层的参数,参照 SE-Net(Squeeze Excitation Network)的常用设置,将压缩率 r 设为 $16^{[27]}$ 。

经过第一层全连接层和 ReLU 激活函数处理后,再经过第二层全连接层和 Sigmoid 激活函数,得到通道注意力权重向量

$$W_C = \text{Sigmoid}(V_2 \cdot \text{ReLU}(V_1 \cdot G(X^{i'}_{2D})))$$
 (9)

将得到的通道注意力权重向量 W_C 与聚合后的特征张量 $X^{i'}_{2D}$ 进行逐通道相乘,得到注意力增强后的特征张量

$$X^{i''}_{2D} = X^{i'}_{2D} \cdot W_C$$
 (10)

最终实现多通道-多周期脉搏信号的自适应特征挖掘。

1.4 高血压分类识别

脉搏信号在多通道、多周期间的特征学习,并对不同周期尺度下的特征信息进行了自适应聚合。为了实现最终的高血压识别,使用两层全连接层实现疾病分类,该过程可表示为

$$y = M_2(R_{1D}(M_1(X'_{2D})))$$
 (11)

式中: $M_1(\cdot)$ 和 $M_2(\cdot)$ 分别表示第一层全连接层

与第二层全连接层的映射处理; $R_{1D}(\cdot)$ 表示将特征维度重构为一维(One-Dimensional, 1D)向量,以便于分类映射处理。

2 实验结果与分析

2.1 数据采集

搭建多通道脉搏采样设备,采集高血压患者与健康受试者左右手“寸”“关”“尺”部的脉搏信号。共纳入 48 名受试者,涵盖不同性别与年龄分布,其中高血压受试者 13 名,健康受试者 35 名。依据中医脉诊理论,精准定位每位受试者左右腕部“寸”“关”“尺”共 6 个脉位,并使用固定装置将 6 个压电式传感器稳定固定于对应脉位处。通过压电式传感器分别采集 6 个脉位的脉搏信号,采集频率为 60 Hz,采集时间为 120 s。采集到的信号经过放大器电路与 A/D 转换后,传输至上位机处理平台,用于后续高血压识别分析。特别地,在采集前 5 min,要求受试者调整情绪与呼吸,保持状态平稳。

2.2 数据预处理

为了获取高信噪比的脉搏信号数据并增强模型训练的鲁棒性,对原始脉搏信号进行预处理,包括平滑、去噪及数据扩充。具体而言,采用小波变换对原始脉搏信号进行平滑处理,并利用巴特沃斯滤波器进行去噪,从而在有效去除噪声的同时保障信号完整性^[28]。此外,采用滑动窗口方式对多通道脉搏数据进行扩充,窗口长度设为 300 个振动幅度值,步长设为 30,单个样本尺度为(6, 300)。该数据扩充策略进一步增强了模型训练的鲁棒性。

预处理后的多通道脉搏信号数据集按 4 : 1 的比例划分为训练集与测试集,各集合的样本数量如表 1 所示。

表 1 训练集、测试集样本数量

类别序号	类别名称	样本数量		
		共计	训练集	测试集
0	健康	2 380	1 904	476
1	高血压	884	707	177

2.3 仿真环境与参数设置

实验均在一台配置为 Intel i9-11900K 处理器、NVIDIA RTX 4070 GPU×2、128 GiB 内存和 1 TB 固态硬盘的计算机上运行。实验参数设置如表 2 所示。其中,损失函数采用交叉熵函数,优化器使用自适应矩估计(Adaptive Moment Estimation, Adam),训练周期数设为 100,学习率设为 0.000 1,重要频率选择数量 k 设为 3,多分支并联 3D 卷积模块

中每分支的卷积核数量设为 3,每批次训练的样本数量设为 32。

表 2 参数说明和默认值设置

参数	默认值
重要频率选择数量 k	3
多尺度周期模式列表	{6,10,12}
每分支下卷积核并联数量	3
第一层全连接层设置	(300,2)
第二层全连接层设置	(12,2)
每批次训练样本数量	32
训练轮数	100
损失函数	交叉熵
优化器	Adam
学习率	0.000 1

为了量化高血压识别的准确程度,采用准确率、精确率、召回率、F1 分数共 4 个指标对高血压识别性能进行评估^[29]。同时,为增强模型泛化能力,采用分层 5 折交叉验证^[30]进行模型评估。具体划分方式为:按类别标签对数据集进行分层,确保每折中高血压样本比例与原始数据一致(约 27.08%)。每次验证时,4 折用于训练,1 折用于测试,最终将 5 次结果的平均值作为模型性能的最终指标。

2.4 关键参数讨论

重要频率选择数量 k 的取值决定了 3D 脉搏张量序列的数量及多分支并联 3D 卷积模块的分支数,进而影响模型的特征学习与疾病识别性能。此外,每个分支下的 3D 卷积核数量以及训练时每批次的样本数量也会影响模型的特征学习过程,合理配置这些参数将协同影响最终的分类性能。下面将进一步分析 k 值、每分支 3D 卷积核数量以及每批次样本数量对模型识别性能的影响。

2.4.1 重要频率选择数量 k 的影响

为探究 k 值对所提方法性能的影响,将重要频率选择数量 k 分别设为 2,3,4,5 进行对比实验,结果如图 4 所示。




图 4 不同 k 值设定下的实验结果

不同 k 值对应的周期数列表为: $k=2$ 时为 [6,10]; $k=3$ 时为 [6,10,12]; $k=4$ 时为 [6,10,12,25]; $k=5$ 时为 [6,10,12,25,30]。随着 k 增大,模型逐步引入周期数更大的重构尺度,即单周期包含的采样点数逐步减少。由图 4 可见,当 $k=2$ 时,仅使用周期数 6 和 10 两个尺度,能够描述较稳定的周期间关联,但对较短周期内的局部变化覆盖不足,因此精确率和 F1 分数相对较低。当 $k=3$ 时,新增周期数 12 的重构分支,与周期数 6 和 10 共同形成“长-中-短”互补的多尺度表征:周期数 6 侧重稳定的跨周期规律,周期数 10 兼顾周期间相关性与周期内变化,周期数 12 进一步补充局部动态细节,使 4 个识别指标整体达到最佳。当 $k=4$ 或 $k=5$ 时,进一步引入周期数 25 和 30,单周期内可用采样点过少,容易放大大局部噪声并产生冗余分支,有限样本条件下还会增加模型拟合难度,因而识别性能下降。综合特征完整性、噪声敏感性与模型复杂度, $k=3$ 取得最优效果,所提方法的识别效果最佳。

为进一步分析 k 值的影响,对 $k=3$ 时多通道下不同周期间对应时刻脉搏信号的相关系数进行分析,相关系数热力图分别如图 5~图 7 所示。其中,对应位置的矩形块颜色越浅,代表对应时刻脉搏信号在多周期间的正相关性越强;颜色越深,则代表负相关性越强。




图 5 周期数为 6 时脉搏信号相关系数热力图




图 6 周期数为 10 时脉搏信号相关系数热力图




图 7 周期数为 12 时脉搏信号相关系数热力图

由图 5 可以看出,当周期数为 6 时,对应时刻脉搏信号大多呈周期内正相关,且部分相邻时刻的信号表现出较强的相关性。这表明在单周期脉搏信号长度较长时,脉搏在单周期内的变化呈现出一定的规律性。图 6 中周期数为 10 时,正相关区域仍较连续,但相较周期数 6 已出现更多局部相关性差异,表明该尺度在保持周期内一致性的同时开始突出周期内动态变化,起到连接全局趋势与局部细节的中间尺度作用。随着周期数的增加,呈正相关的矩形块数量相对减少,意味着脉搏信号的局部动态变化较为明显,这有助于模型对脉搏信号周期内变化特性的挖掘。图 7 中周期数为 12 时,部分区域的相关性进一步减弱并出现较明显负相关,说明较短单周期序列更敏感于局部波形变化。3 种尺度分别提供稳定全局关联、过渡性动态模式和局部细节信息,形成互补表征,这与图 4 中 $k=3$ 取得最佳结果一致。若继续引入周期数 25 和 30,单周期采样点显著减少,局部噪声和特征碎片化风险增大,模型容易过度关注局部变化而削弱全局规律建模,结合 k 值设定的结果来看,当 k 值过大时,周期长度序列中会引入较大的周期数,导致单周期内的脉搏信号数量减少。此时,模型可能过于倾向于挖掘脉搏张量的局部特性,从而影响最终的识别性能。因此,选择合适的 k 值有助于模型充分利用周期内与周期内的特征,从而实现准确的高血压识别。

2.4.2 多分支并联 3D 卷积模块的影响

将 3D 卷积核的并联数量设置在 $[2,6]$ 区间进行实验,各数量对应的卷积核尺寸如表 3 所示。

表 3 多分支卷积核尺寸

每分支 3D 卷积核并联数	对应的卷积核尺寸列表
2	$\{1 \times 3 \times 3, 1 \times 5 \times 5\}$
3	$\{1 \times 3 \times 3, 1 \times 5 \times 5, 1 \times 7 \times 7\}$

续表 3 多分支卷积核尺寸

每分支 3D 卷积核并联数	对应的卷积核尺寸列表
4	$\{1 \times 3 \times 3, 1 \times 5 \times 5, 1 \times 7 \times 7, 1 \times 9 \times 9\}$
5	$\{1 \times 3 \times 3, 1 \times 5 \times 5, 1 \times 7 \times 7, 1 \times 9 \times 9, 1 \times 11 \times 11\}$
6	$\{1 \times 3 \times 3, 1 \times 5 \times 5, 1 \times 7 \times 7, 1 \times 9 \times 9, 1 \times 11 \times 11, 1 \times 13 \times 13\}$

不同 k 值与 3D 卷积核数量设置下,所提方法准确率对比结果如图 8 所示。




图 8 k 值与卷积核数对准确率的影响

由图 8 可以看出,当每分支下 3D 卷积核数量设置为 3 时,所提方法达到最佳识别准确率 99.34%。当卷积核数量大于 3 时,准确率呈下降趋势。这一现象可能与超参数 k 的设定密切相关。前述实验已表明, k 值过大会引入数值较大的周期模式,导致单周期内脉搏信号数量减少,从而使模型难以准确学习脉搏信号的局部变化模式。因此,合理设置超参数 k 及每分支下 3D 卷积核的数量至关重要。本文在 $k=3$ 的前提下,将每分支 3D 卷积核的数量设为 3。

2.4.3 每批次训练样本数量设置的影响

由于脉搏信号样本量相对局限,且健康受试者与高血压受试者的样本分布不均衡,不合理的每批次样本数量设置会对模型的训练精度产生负面影响。为此,将每批次训练样本数量分别设为 16,32,64 进行对比实验,结果如图 9 所示。可以看出,当每批次训练样本数量设为 32 时,所提方法的准确率、精确率及 F1 分数均达到最佳,分别为 99.34%、99.52% 及 99.13%。当每批次训练样本数量设为 64 时,测试结果远低于较小每批次训练样本数量下的结果,尤其是召回率仅为 95.81%。这主要是由于脉搏信号数据的有限性和特殊性,过大的每批次训练样本数量可能使梯度更新过度依赖当前批次的样本特征,导致梯度估计出现偏差。而当每批次训练样本数量设为 16 时,由于健康受试者与高血压

受试者的样本分布不均衡,模型在每批次内无法充分学习到两类样本的特征,从而影响模型的识别性能。因此,选择每批次训练样本数量为32,使模型能够充分学习健康与高血压两类脉搏信号的潜在信息。




图9 不同每批次训练样本数量设置下的实验结果

2.5 消融实验

设计两种对比实验验证脉搏信号多通道-多周期特征融合分析的有效性。

实验1 基于多通道2D脉搏信号,采用全连接层对多通道脉搏信号序列进行分类。

实验2 基于多通道-多周期3D脉搏张量,实现基于脉搏信号自适应重构的高血压识别。

在多通道脉搏信号数据集上的消融实验结果表明,相较于实验1,实验2在4个评估指标上均有较为明显的提升。特别是精确率与F1分数,分别提高了13.37%与12.6%。这说明对脉搏信号进行周期间与周期内的时空特征挖掘,能够显著提升健康受试者与高血压受试者的识别效果。综上,挖掘脉搏信号在周期间及周期内的变化模式,可有效增强高血压识别的准确性。

2.6 对比实验

为了验证所提方法在高血压识别任务中的有效性,将所提方法与不同类型的脉搏特征提取方法进行对比,包括长短期记忆网络(Long Short-Term Memory, LSTM)、门控循环单元(Gated Recurrent Unit, GRU)、一维卷积神经网络(One-Dimensional Convolutional Neural Network, 1D-CNN)、图神经网络(Graph Neural Network, GNN)、图卷积网络(Graph Convolutional Network, GCN)和图注意力网络(Graph Attention Network, GAT)。特别地, LSTM与GRU在输入时通常需要对数据进行2D重构,即对脉搏信号进行周期划分。为保障实验的公平性,实验将LSTM和GRU的周期数分别设为6,10,12,分别记为LSTM-6、LSTM-10、LSTM-12、

GRU-6、GRU-10和GRU-12,此外,将6个脉位通道的特征作为GNN、GCN及GAT的节点。不同方法准确率对比结果如图10所示。




图10 不同方法准确率对比结果

由图10可以看出,与其他类型的高血压识别方法相比,所提方法具有最佳准确率99.34%。基于图结构的方法GAT、GCN和GNN的识别准确率次之,分别为98.42%、98.07%、97.65%,这也进一步说明了脉位通道间的信息交互有益于脉搏信号的疾病识别。另外,从LSTM与GRU设置不同周期数的结果可以看出,随着LSTM周期数的增加,模型能够更好地学习序列数据中的长期依赖关系,从而提升准确率;但当周期数进一步增加到12时,准确率有所下降。这表明周期数过多时,模型无法充分学习周期内的变化模式。相比之下,所提方法能够挖掘不同周期数下3D脉搏张量在周期间与周期内的潜在特征表征,充分学习特征在通道间、周期间的动态规律,从而缓解单周期内搏动幅值数量较少时带来的周期内特征学习局限。

3 结语

针对现有高血压识别方法难以同时捕捉脉搏信号的多通道特征与跨周期动态变化的问题,提出了一种基于脉搏信号的自适应三维重构高血压识别方法。该方法通过FFT提取信号的主要频段,并基于此自适应地重构出“通道×周期×时序”三维特征张量。这一过程不仅融合了多通道信息,而且同时建模了周期内的局部细节变化以及周期间的全局动态关联,克服了传统单周期或多周期分析方法视角单一的局限。实验结果表明,在自建的高血压/健康人六通道脉搏数据集上,所提方法获得了最高的识别准确率99.34%,相较于LSTM和1D-CNN等基线模型,准确率分别提升了7.17%和4.84%。

消融实验进一步表明,引入自适应 3D 重构及特征挖掘模块后,使模型的精确率和 F1 分数分别提升了 13.37% 和 12.6%,表明通过三维建模同步提取多通道与跨周期特征,比单纯的序列建模或图结构建模更能充分利用脉搏信号中的信息,验证了多通道与多周期协同建模的有效性。

参 考 文 献

[1] 曲扬, 窦德强, 王丽娜, 等. 学四诊之法把结构之脉[J]. 中国中医药现代远程教育, 2025, 23(1): 95-98.
Qu Yang, Dou Deqiang, Wang Lina, et al. Learning the four diagnostic methods and grasping the pulse of structure[J]. Chinese Medicine Modern Distance Education of China, 2025, 23(1): 95-98.

[2] 何卫俊, 刘雍陶, 刘登吉, 等. 基于体外实验的光电容积脉搏波信号检测及脉率特性[J]. 医用生物力学, 2024, 39(4): 712-717.
He Weijun, Liu Yongtao, Liu Dengji, et al. Photoplethysmography pulse wave signal detection and pulse rate characteristics based on an in vitro experiment[J]. Journal of Medical Biomechanics, 2024, 39(4): 712-717.

[3] 武振亚, 马红梅, 王丽娟, 等. 臂踝脉搏波传导速度与 2 型糖尿病患者心脏结构和功能相关性的研究[J]. 中国糖尿病杂志, 2024, 32(9): 641-645.
Wu Zhenya, Ma Hongmei, Wang Lijuan, et al. Correlation between brachial and ankle pulse wave velocity and cardiac structure and function in type 2 diabetes mellitus patients[J]. Chinese Journal of Diabetes, 2024, 32(9): 641-645.

[4] 梁国良, 阚珊珊, 马江伟, 等. 颈一股脉搏波传导速度与冠心病患者左室舒张功能的相关性及诊断价值[J]. 齐齐哈尔医学院学报, 2024, 45(20): 1919-1924.
Liang Guoliang, Kan Shanshan, Ma Jiangwei, et al. Correlation between carotid-femoral pulse wave conduction velocity and left ventricular diastolic function in patients with coronary artery disease and its diagnostic value[J]. Journal of Qiqihar University of Medicine, 2024, 45(20): 1919-1924.

[5] 衣凯, 张梦笛, 郭沈, 等. 中医脉诊智能化设备数据标注的研究述评[J]. 上海中医药杂志, 2024, 58(10): 5-10.
Yi Kai, Zhang Mengdi, Guo Shen, et al. Research review on data annotation for intelligent pulse diagnosis devices in traditional Chinese medicine[J]. Shanghai Journal of Traditional Chinese Medicine, 2024, 58(10): 5-10.

[6] 张晓丹, 杨玉雨, 张璐, 等. CNN-SEAttBiGRU 的帕金森病患脑电信号识别方法[J]. 西安工程大学学报, 2026, 40(2): 72-81.
Zhang Xiaodan, Yang Yuyu, Zhang Lu, et al. EEG signal recognition method for Parkinson's disease patients using CNN-SEAttBiGRU[J]. Journal of Xi'an Polytechnic University, 2026, 40(2): 72-81.

[7] 王忠民, 雷欢. 基于社区间脑电信号的因果网络情绪识别方法[J]. 西安邮电大学学报, 2025, 30(6): 59-67.
Wang Zhongmin, Lei Huan. Causal network emotion recognition method based on EEG signals between communities[J]. Journal of Xi'an University of Posts and Telecommunications, 2025, 30(6): 59-67.

[8] 潘晓英, 王佳, 刘妮, 等. 机器学习在医疗大数据中的应用[J]. 西安邮电大学学报, 2020, 25(1): 21-33.
Pan Xiaoying, Wang Jia, Liu Ni, et al. Application of machine learning in large medical data[J]. Journal of Xi'an University of Posts and Telecommunications, 2020, 25(1): 21-33.

[9] 史延新. 结合边缘检测和区域方法的医学图像分割算法[J]. 西安工程大学学报, 2010, 24(3): 320-323.
Shi Yanxin. The medical image segmentation algorithm based on edge detection and regional growth[J]. Journal of Xi'an Polytechnic University, 2010, 24(3): 320-323.

[10] Fan L, Chen T Y, He L, et al. GADM: Data augmentation using Generative Adversarial Diffusion Model for pulse-based disease identification[J]. Biomedical Signal Processing and Control, 2025, 100: 107005.

[11] Yi K, Ma Y J, Guo S, et al. Research and development of the pulse acquisition system and the pulse biomimetic reproduction system[J]. Journal of Traditional Chinese Medicine, 2025, 45(1): 213-220.

[12] Martis R J, Acharya U R, Min L C. ECG beat classification using PCA, LDA, ICA and discrete wavelet transform[J]. Biomedical Signal Processing and Control, 2013, 8(5): 437-448.

[13] Cui J, Song L C. Wrist pulse diagnosis of stable coronary heart disease based on acoustics waveforms[J]. Computer Methods and Programs in Biomedicine, 2022, 214: 106550.

[14] Fan L, Shi X M, Wang Z M, et al. Disease identification method based on graph features between pulse cycles[J]. Biomedical Signal Processing and Control, 2023, 83: 104670.

[15] Jiang Z X, Guo C X, Zang J, et al. Features fusion of multichannel wrist pulse signal based on KL-MGDCCA and decision level combination[J]. Biomedical Signal

- Processing and Control, 2020, 57: 101751.
- [16] Cao Y J, Li P, Zhu Y R, et al. Artificial intelligence-enabled novel atrial fibrillation diagnosis system using 3D pulse perception flexible pressure sensor array[J]. ACS Sensors, 2025, 10(1): 272-282.
- [17] 罗静静, 左晶晶, 季仲致, 等. 面向脉诊客观化的脉搏传感器研究综述[J]. 仪器仪表学报, 2021, 42(8): 1-14.
- Luo Jingjing, Zuo Jingjing, Ji Zhongzhi, et al. Research review on pulse sensors for pulse diagnosis objectification[J]. Chinese Journal of Scientific Instrument, 2021, 42(8): 1-14.
- [18] 崔骥, 费兆馥, 张志枫, 等. 平、滑、弦脉的脉图分类参数范围研究[J]. 上海中医药杂志, 2016, 50(12): 15-17.
- Cui Ji, Fei Zhaofu, Zhang Zhifeng, et al. Classification parameter range of pulse graphs of normal pulse, slippery pulse and taut pulse[J]. Shanghai Journal of Traditional Chinese Medicine, 2016, 50(12): 15-17.
- [19] Li N, Yu J R, Hu H Q, et al. The correlation study of Cun, Guan and Chi position based on wrist pulse characteristics[J]. IEEE Access, 2021, 9: 28917-28929.
- [20] Fan L, Dang B C, Wang Z M, et al. Multimodal 1D-to-2D signal transformation and pulse disease recognition[C]//2023 6th International Conference on Artificial Intelligence and Pattern Recognition. Xiamen: ACM, 2023: 324-330.
- [21] Bautista V M, Garrido M. A method to obtain non-power-of-two FFT flow graphs based on a new prime factor algorithm[J]. IEEE Transactions on Signal Processing, 2025, 73: 1004-1017.
- [22] Filho E P S, Santos A D, Filho E F S, et al. Hilbert-Huang transform with intelligent noise reduction for passive SONAR signal processing[J]. IEEE Journal of Oceanic Engineering, 2025, 50(2): 1387-1402.
- [23] Heo J, Jung Y, Lee S, et al. FPGA implementation of an efficient FFT processor for FMCW radar signal processing[J]. Sensors, 2021, 21(19): 6443.
- [24] Zhang D, Wang H, Feng Y, et al. Fast Fourier transform (FFT) using flash arrays for noise signal processing[J]. IEEE Electron Device Letters, 2022, 43(8): 1207-1210.
- [25] Wu H X, Hu T G, Liu Y, et al. TimesNet: Temporal 2D-variation modeling for general time series analysis[C]//International Conference on Learning Representations, Kigali: ICLR, 2023: 22-44.
- [26] Liu Z Y, Yang C, Huang J, et al. Deep learning framework based on integration of S-Mask R-CNN and Inception-v3 for ultrasound image-aided diagnosis of prostate cancer[J]. Future Generation Computer Systems, 2021, 114: 358-367.
- [27] Hu J, Shen L, Sun G. Squeeze-and-Excitation Networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 7132-7141.
- [28] Shi G, Qin C J, Zhang Z N, et al. Towards complex multi-component pulse signal with strong noise: Deconvolution and time-frequency assisted mode decomposition[J]. Mechanical Systems and Signal Processing, 2024, 212: 111274.
- [29] Amin Ali O M, Wahhab Kareem S, Mohammed A S. Evaluation of electrocardiogram signals classification using CNN, SVM, and LSTM algorithm: A review [C]//2022 8th International Engineering Conference on Sustainable Technology and Development. Erbil: IEEE, 2022: 185-191.
- [30] 贺兴时, 李锦, 梁芸芸. 基于多源特征和双向门控循环单元的抗高血压脉识别[J]. 西安工程大学学报, 2023, 37(3): 109-114.
- He Xingshi, Li Jin, Liang Yunyun. Identification of anti-hypertensive peptides based on multi-source features and bidirectional gated recurrent units[J]. Journal of Xi'an Polytechnic University, 2023, 37(3): 109-114.

[作者简介]



范琳(1982—),女,湖北钟祥人,西安邮电大学副教授,主要研究方向为脉搏疾病识别、机器学习等。E-mail: fanlin@xupt.edu.cn



白若昱(1996—),男,陕西西安人,西安邮电大学硕士研究生,主要研究方向为脉搏疾病识别、深度学习。E-mail: yrb@stu.xupt.edu.cn

[责任编辑:祝 剑]