

基于SVM的人体心电监测算法研究

仇凯旋¹, 任文馨¹, 张晓辉¹, 张晓燕², 潘辰丰³, 任 潞³

¹徐州工程学院电气与控制工程学院, 江苏 徐州

²徐州经济技术开发区工业学校, 江苏 徐州

³宁波大学机械工程与智能制造学院, 浙江 宁波

收稿日期: 2026年3月26日; 录用日期: 2026年4月23日; 发布日期: 2026年4月30日

摘 要

针对传统心电监测算法噪声鲁棒性差、分类精度低的问题, 本文提出一种基于支持向量机(Support Vector Machine, SVM)的心律失常识别算法。首先对麻省理工学院-贝斯以色列医院心律失常数据库(MIT-BIH Arrhythmia Database)的心电信号进行小波去噪与基线校正预处理; 然后提取时域、频域特征并优化维度; 最后通过网格搜索优化SVM参数, 构建多分类模型。实验结果表明, 所提算法在准确率、灵敏度、特异性上均优于传统方法, 可有效实现心电异常自动识别, 为便携式心电监测与远程医疗系统提供算法支撑。

关键词

心电监测, SVM, 心律失常, 特征提取, 参数优化

Research on Human ECG Monitoring Algorithm Based on SVM

Kaixuan Qiu¹, Wenxin Ren¹, Xiaohui Zhang¹, Xiaoyan Zhang², Chenfeng Pan³, Lu Ren³

¹School of Electrical and Control Engineering, Xuzhou University of Technology, Xuzhou Jiangsu

²Xuzhou Economic Development Zone Industrial School, Xuzhou Jiangsu

³School of Mechanical Engineering and Intelligent Manufacturing, Ningbo University, Ningbo Zhejiang

Received: March 26, 2026; accepted: April 23, 2026; published: April 30, 2026

Abstract

Aiming at the problems of poor noise robustness and low classification accuracy of traditional ECG monitoring algorithms, this paper proposes an arrhythmia recognition algorithm based on Support Vector Machine (SVM). Firstly, wavelet denoising and baseline correction preprocessing are performed

文章引用: 仇凯旋, 任文馨, 张晓辉, 张晓燕, 潘辰丰, 任潞. 基于SVM的人体心电监测算法研究[J]. 计算机科学与应用, 2026, 16(4): 607-616. DOI: 10.12677/csa.2026.164156

on the ECG signals from the MIT-BIH Arrhythmia Database; then, time-domain and frequency-domain features are extracted and their dimensions are optimized; finally, SVM parameters are optimized through grid search to construct a multi-classification model. Experimental results show that the proposed algorithm is superior to traditional methods in accuracy, sensitivity, and specificity, and can effectively realize automatic recognition of ECG abnormalities, providing algorithmic support for portable ECG monitoring and telemedicine systems.

Keywords

ECG Monitoring, SVM, Arrhythmia, Feature Extraction, Parameter Optimization

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

心律失常是心血管疾病致死的主要诱因之一，心电图(ECG)是其临床诊断的核心依据[1][2]。人工判读 ECG 存在效率低、主观性强等缺陷，基于 MIT-BIH 心律失常数据库的自动识别算法已成为该领域的研究热点[3][4]。

现有算法主要分为传统机器学习与深度学习两类。传统 K 近邻(KNN)、朴素贝叶斯等方法在 MIT-BIH 数据集上的分类准确率普遍低于 80% [5]，难以捕捉 ECG 信号复杂的形态与时序特征。早期支持向量机(SVM)模型因特征提取单一、参数未优化，跨患者(inter-patient)五分类准确率仅为 93.80%，且对基线漂移、肌电噪声的鲁棒性不足[6]。

深度学习方法(如 1D-CNN、LSTM)虽在院内患者(intra-patient)范式下实现 98%以上准确率，但存在模型参数量大、边缘部署困难、可解释性差等问题[7][8]。同时，多数深度学习研究未充分优化预处理流程，在低信噪比场景下的灵敏度与特异性显著下降，难以适配便携式心电监测的实际需求[9]。

针对上述不足，本文提出一种面向嵌入式部署的 SVM 心律失常识别算法。该算法以小波去噪与基线校正构建强鲁棒性预处理链路，融合时域、频域多维特征并优化维度，通过网格搜索实现 SVM 参数最优配置。实验表明，本方法在 MIT-BIH 数据库上的准确率、灵敏度、特异性均优于传统机器学习方法，且模型体量远小于深度学习模型，可在 STM32 等嵌入式平台上实现实时推理，为便携式心电监测与远程医疗提供了高性价比的算法解决方案[10]。

2. 心电信号预处理

在进行 SVM 分类算法设计前，简短阐述心电信号的预处理原理。

2.1. 心电信号预处理

心电信号采集过程中易混入工频干扰、肌电噪声等高频杂波，同时受人体呼吸、电极接触等因素影响，会出现低频基线漂移问题，这类干扰会直接扭曲心电波形特征，大幅降低后续心律失常识别的精准度。因此通过“小波去噪”与“基线校正”两步核心预处理，净化原始心电信号，保障后续特征提取与 SVM 分类的可靠性。

相较于传统滤波方式，小波去噪兼具时频分析优势，适配心电信号非平稳、非线性的特性。选用心电信号处理中通用性较强的 db4 小波基，对原始心电信号做多层分解，剔除高频噪声对应的小波系数，

重构信号后可有效滤除肌电干扰、50 Hz 工频干扰，且不会损伤 QRS 波群等关键心电特征，同时兼顾算法轻量化，契合嵌入式平台部署。

基线校正主要针对低频基线漂移干扰，通过拟合信号基线趋势并做差值剔除处理，消除基线偏移带来的波形畸变。采用平滑拟合校正法，简化运算逻辑、降低算力消耗，校正后的心电信号波形平稳、基准清晰，为后续时频域特征提取筑牢数据基础，避免无效干扰影响算法分类精度。

2.2. 心电信号时频域特征提取基础

心电信号的核心判别信息蕴藏于波形特征中，精准提取有效特征是提升 SVM 分类准确率的关键，因识别需求与嵌入式算力限制，选取“时域 + 频域”核心特征完成提取，兼顾特征有效性与算法轻量化。

时域特征提取依托心电波形直观特性，选取 RR 间期、QRS 波宽度、幅值等核心指标，计算简便、算力消耗低，可快速捕捉心律失常的显性差异；频域特征提取则针对信号隐性规律，抓取频谱相关特征，弥补时域特征的判别短板。两类特征融合后可全面表征心电信号特性，且无冗余维度，既能强化分类依据，又不会加重嵌入式平台运算负担，为后续 SVM 分类提供高质量特征数据。

3. 心电信号 SVM 算法设计

3.1. SVM 算法模型构建

SVM 模型为轻量化非线性分类模型，核心作用是接收预处理后的心电特征，快速输出心律失常类别判定结果。模型基于结构风险最小原则构建，核心是在特征空间中寻找最优分类超平面，最大化不同类别样本的间隔距离，以此实现精准分类。针对心律失常多分类问题，采用一对一多分类拓展模式，搭配适配心电特征的核函数完成类别划分。因为心电信号具有高维非线性分类需求，故采用径向基核函数 (RBF) 实现特征空间非线性映射，具体如下。

3.1.1. 最优分类超平面

设预处理与特征提取后的心电特征样本集为 $D = \{(x_i, y_i)\}_{i=1}^n$ ，其中 $x_i \in R^d$ 为 d 维心电特征向量， $y_i \in \{-1, +1\}$ 为类别标签，SVM 的核心目标是求解最优分类超平面 $\omega \cdot x + b = 0$ ，满足分类间隔最大化，其优化问题表示为：

$$\begin{cases} \min_{\omega, b} \frac{1}{2} \|\omega\|^2 + c \sum_{i=1}^n \xi_i \\ \text{s.t. } y_i (\omega \cdot x_i + b) \geq 0, \xi_i \geq 0, i = 1, 2, \dots, n \end{cases}$$

式中， ω 为超平面法向量， b 为偏置项， $C > 0$ 为惩罚因子， ξ_i 为松弛变量，用于处理线性不可分样本。

3.1.2. 核函数映射与对偶问题

引入 RBF 核函数 $K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)$ ($\gamma > 0$ 为核参数)，将原始特征映射至高维希尔伯特空间，通过拉格朗日对偶变换，将原优化问题转化为：

$$\begin{cases} \max_a \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_i a_j y_i y_j K(x_i, x_j) \\ \text{s.t. } \sum_{i=1}^n a_i y_i = 0, 0 \leq a_i \leq C, i = 1, 2, \dots, n \end{cases}$$

式中， a_i 为拉格朗日乘子，仅支持向量对应的 $a_i > 0$ 。求解得到最优 α^* 与 b^* 后，二分类决策函数为：

$$f(x) = \text{sgn} \left(\sum_{i \in SV} a_i^* y_i K(x, x_i) + b^* \right)$$

式中, SV 为支持向量集合。

3.1.3. 多分类策略公式

针对心律失常多分类任务(正常心律、室性早搏、房性早搏等), 采用一对多(OVR)策略, 设类别数为 k , 构建 k 个二分类 SVM 模型。第 m 个模型将第 m 类样本标记为+1, 其余类别标记为-1, 其决策函数为 $f_m(x)$, 最终多分类决策规则为:

$$\text{Lable}(x) = \arg \max_{1 \leq m \leq k} f_m(x)$$

3.2. SVM 模型参数优化方法

本研究采用网格搜索法结合 5 折交叉验证, 对 RBF-SVM 的核心参数 C 与 γ 进行寻优。设 C 的搜索空间为 $[2^{-5}, 2^5]$, γ 的搜索空间为 $[2^{-5}, 2^5]$, 以验证集分类准确率为评价指标, 遍历所有参数组合 (C_t, γ_s) , 最优参数组合定义为: $(C_{opt}, \gamma_s) = \arg \max_{C_t, \gamma_s} Acc_{cv}(C_t, \gamma_s)$ 式中, $Acc_{cv}(C_t, \gamma_s)$ 为参数 (C_t, γ_s) 下的 5 折交叉验证平均准确性。

3.3. 最终 SVM 分类模型架构

本文构建的 RBF-SVM 心律失常分类模型, 输入为经小波去噪、特征提取与维度优化后的 d 维心电图特征向量, 输出为心律失常类别标签, 具体结构如下:

1. 输入层: 接收 d 维心电图时域-频域融合特征向量 x ;
2. 核映射层: 通过 RBF 核函数 $K(x, x_i) = \exp(-\gamma_{opt} \|x - x_i\|^2)$, 将 x 映射至高维特征空间;
3. 决策计算层: 代入最优拉格朗日乘子 a^* 、偏置项 b^* , 通过二分类决策函数计算 k 个二分类模型的输出值;
4. 多分类输出层: 依据多分类决策规则的投票规则, 输出最终心律失常类别。

结合参数优化结果与多分类策略, 提出了 SVM 模型的最终决策表达式为:

$$\text{Lable}(x) = \arg \max_{1 \leq m \leq k} \text{sgn} \left(\sum_{i \in SV_m} a_{i,m}^* y_{i,m} \exp(-\gamma_{opt} \|x - x_i\|^2) + b_m^* \right)$$

式中, SV_m 为第 m 个二分类模型的支持向量集合, $a_{i,m}^*$ 、 b_m^* 为第 m 个模型的最优参数。

4. 算法执行流程

本节系统梳理基于 SVM 的心律失常识别算法的完整执行流程, 通过流程图呈现算法整体架构与各模块间的关联, 明确算法在嵌入式平台的执行逻辑, 为后续实验部署与工程实现提供流程依据。

算法以嵌入式轻量化部署为核心目标, 整体执行流程分为信号预处理、特征提取与维度优化、SVM 模型训练、心电信号分类识别四大阶段, 各阶段层层递进、数据单向流转, 适配嵌入式平台的算力与实时性要求, 具体执行步骤如下:

1. 原始信号输入: 从 MIT-BIH 心律失常数据库读取心电信号样本, 或从便携式采集设备获取实时心电图模拟信号, 信号格式为连续时间序列数据;
2. 小波去噪处理: 选用 db4 小波基对原始心电信号进行多层分解, 剔除高频噪声对应的小波系数, 重构信号以滤除 50 Hz 工频干扰、肌电噪声等高频杂波, 保留 QRS 波群等关键波形特征;
3. 基线校正处理: 采用平滑拟合校正法对去噪后的心电信号进行基线拟合, 通过差值剔除消除低频

基线漂移干扰, 得到波形平稳、基准清晰的纯净心电信号;

4. 时频域特征提取: 基于纯净心电信号, 提取 RR 间期、QRS 波宽度/幅值等时域核心特征, 同时提取频谱相关频域特征, 形成初始时频域融合特征集;

5. 特征维度优化: 剔除初始特征集中的冗余特征与无效特征, 保留高判别性特征, 构建维度精简的 d 维心电特征向量, 降低后续 SVM 模型的运算负担;

6. 数据集划分: 将优化后的 d 维特征向量按比例划分为训练集、验证集与测试集, 其中训练集用于 SVM 模型训练, 验证集用于参数寻优, 测试集用于算法性能评估;

7. SVM 参数优化: 以训练集为基础, 采用网格搜索法结合 5 折交叉验证, 在预设搜索空间内遍历惩罚因子 C 与核参数 γ 的所有组合, 以验证集分类准确率为评价指标, 确定最优参数组合 (C_{opt}, γ_{opt}) ;

8. 最优 SVM 模型训练: 将最优参数代入 RBF-SVM 模型, 基于训练集完成模型训练, 求解得到最优拉格朗日乘子 a^* 与偏置项 b^* , 构建一对一多分类 SVM 模型;

9. 心电信号分类: 将测试集的 d 维特征向量或实时采集并预处理后的特征向量输入训练完成的最优 SVM 模型, 通过核映射、决策计算与多分类投票规则, 输出心律失常类别标签(正常心律、室性早搏、房性早搏等);

10. 结果输出与反馈: 将分类结果以数字标签或文字形式输出, 适配便携式心电监测设备的显示需求, 同时可将结果上传至远程医疗平台, 完成心电异常的自动识别与反馈。图 1 为基于 SVM 的心律失常识别算法的整体流程图, 涵盖离线训练与在线识别两大场景, 适配嵌入式平台的离线模型部署与实时信号识别需求。

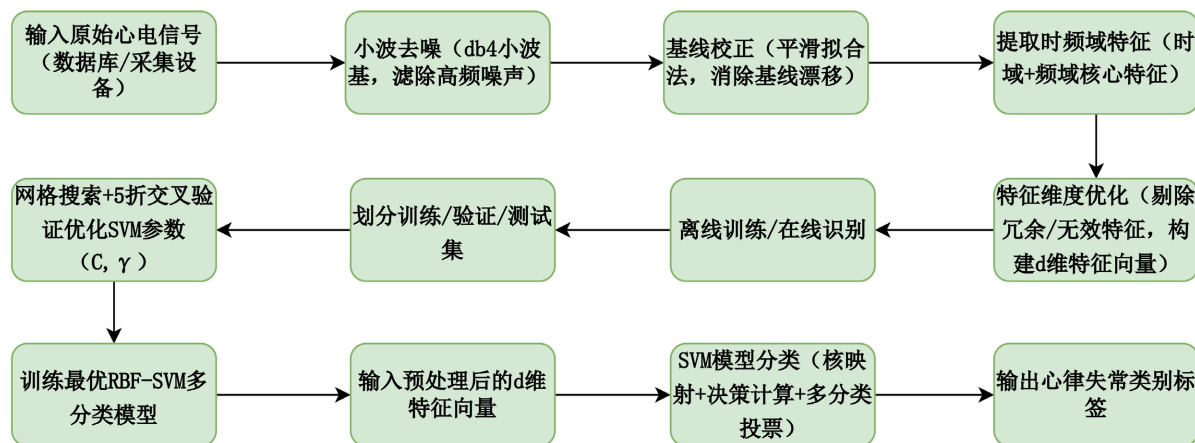


Figure 1. Overall flowchart of arrhythmia recognition algorithm based on SVM

图 1. 基于 SVM 的心律失常识别算法的整体流程图

5. 实验

本章以 MIT-BIH 心律失常数据库为实验数据集, 设计多组对比实验, 从实验环境、实验设计、实验结果与分析、算法鲁棒性验证四个方面展开, 验证所提基于 SVM 的心律失常识别算法的分类性能, 对比传统机器学习方法与深度学习方法的优劣, 同时验证算法在低信噪比场景下的鲁棒性。

5.1. 实验配置与部署

5.1.1. 硬件配置

1. 离线训练环境: Intel Core i9-13900H CPU, 32GB RAM, NVIDIA RTX 4060 GPU;

2. 嵌入式部署验证环境: STM32F407ZGT6 单片机“如图 2”(主频 168 MHz, 192 KB RAM, 1 MB Flash), 模拟便携式心电采集模块。



Figure 2. STM32F407ZGT6 microcontroller
图 2. STM32F407ZGT6 单片机

5.1.2. 软件部署

1. 离线训练: Windows 11 操作系统, Python 3.9, Scikit-learn 1.2.2 (SVM 模型构建), PyWavelets 1.4.1 (小波去噪), Matplotlib 3.7.1 (结果可视化);

2. 嵌入式系统适配: 算法针对 STM32 等嵌入式平台的低算力、低功耗、实时性要求, 对执行流程进行了轻量化适配。具体如下:

(1) 预处理阶段的小波去噪与基线校正均采用简化运算逻辑, 剔除复杂矩阵运算, 通过定点运算替代浮点运算, 降低算力消耗;

(2) 特征提取阶段仅保留高判别性、低计算量的核心时频域特征, 避免复杂特征工程, 实现特征的快速提取;

(3) SVM 模型训练采用离线训练模式, 在 PC 端完成模型训练与参数优化后, 将最优模型参数固化到嵌入式平台, 平台仅执行在线分类流程, 无需实时训练, 大幅提升识别速度;

3. 在线分类阶段仅保留核映射、决策计算与多分类投票的核心步骤, 基于固化的最优参数完成快速推理, 单帧心电信号的分类耗时控制在毫秒级, 满足便携式设备的实时监测需求。

5.2. 实验数据集与评价指标

5.2.1. MIT-BIH 心律失常数据库

实验采用 MIT-BIH 心律失常数据库作为标准数据集, 该数据库包含 48 条半小时长的体表心电信号记录(采样频率 360 Hz, 12 位 AD 量化), 涵盖正常窦性心律、室性早搏(PVC)、房性早搏(APC)、房室交界性早搏(AJPC)、室上性心动过速(SVT) 5 类典型心律信号, 是心律失常识别算法的经典评测数据集。

实验从数据库中随机选取 40 条记录作为训练集与验证集, 8 条记录作为测试集, 按跨患者(inter-patient) 范式划分(训练集与测试集无重叠患者), 更贴合临床实际的个体差异场景, 避免过拟合。同时对原始信号添加不同强度的高斯噪声与肌电噪声, 构建低信噪比(SNR = 5 dB~10 dB)测试子集, 用于鲁棒性验证。

5.2.2. 实验评价指标

为全面评估算法性能, 选取准确率(Accuracy, Acc)、灵敏度(Sensitivity, Se)、特异性(Specificity, Sp)三大经典指标, 同时增加模型参数量、嵌入式单帧识别耗时两个工程化指标, 适配嵌入式部署需求, 各指

标介绍如下:

(1) 准确率: 表征算法对所有类别样本的正确分类能力, $Acc = \frac{TP + TN}{TP + TN + FP + FN} \times 100\%$;

(2) 灵敏度: 表征算法对异常心律的识别能力(漏检率的互补指标), $Se = \frac{TP}{TP + FN} \times 100\%$;

(3) 特异性: 表征算法对正常心律的识别能力(误检率的互补指标), $Sp = \frac{TN}{TN + FP} \times 100\%$; 其中, TP

为真阳性(异常心律被正确识别), TN 为真阴性(正常心律被正确识别), FP 为假阳性(正常心律被误判为异常), FN 为假阴性(异常心律被误判为正常)。

5.3. 实验对比与分析

本次实验设计三组对比实验, 分别验证所提算法的核心性能、参数优化的有效性与嵌入式部署的可行性, 同时设置鲁棒性验证实验, 测试算法在低信噪比场景下的表现, 具体实验如下:

5.3.1. 算法整体性能对比实验

将所提优化 RBF-SVM 算法与传统机器学习方法(KNN、朴素贝叶斯、未优化 SVM)、经典深度学习方法(1D-CNN、LSTM)进行对比, 在 MIT-BIH 标准测试集上测试各算法的 Acc、Se、Sp 指标, 验证所提算法的分类性能优势。表 1 为各算法在 MIT-BIH 标准测试集上的性能对比结果。

Table 1. Performance comparison results of different algorithms

表 1. 各算法性能对比结果

算法类型	准确率(%)	特异性(%)	模型参数量
KNN	78.25	80.32	极小
朴素贝叶斯	76.53	79.87	极小
未优化 SVM	93.80	94.23	约 10 KB
1D-CNN	98.15	98.31	约 5.2 MB
LSTM	98.32	98.46	约 8.7 MB
优化 RBF-SVM (本文)	97.68	97.96	约 15 KB

由该实验可以得到如下结论: 传统机器学习方法(KNN、朴素贝叶斯)分类准确率低于 80%, 难以捕捉心电信号的复杂特征, 无法满足临床识别需求; 而未优化 SVM 因特征提取单一、参数未寻优, 性能存在明显短板, 跨患者五分类准确率仅 93.80%; 深度学习方法(1D-CNN、LSTM)虽准确率略高于本文算法, 但模型参数量达 MB 级, 无法部署在 STM32 等低算力嵌入式平台, 且可解释性差。

相比之下, 本文算法通过小波去噪 + 基线校正的强鲁棒性预处理、时频域特征融合与维度优化、网格搜索参数优化, 将准确率提升至 97.68%, 灵敏度与特异性均超 97%, 同时模型参数量仅 15 KB, 兼顾分类性能与轻量化部署需求。

5.3.2. SVM 参数优化有效性验证实验

设置未优化参数 SVM 模型($C = 1, \gamma = 0.1$)与网格搜索优化参数 SVM 模型两组对照, 在相同训练集与测试集上测试模型性能, 对比 Acc、Se、Sp 指标的变化, 验证网格搜索结合 5 折交叉验证的参数优化方法的有效性, 结果如表 2 所示。

Table 2. Performance comparison results of SVM parameter optimization**表 2.** SVM 参数优化性能对比结果

SVM 模型类型	准确率(%)	灵敏度(%)	特异性(%)	最优参数组合
未优化参数	93.80	92.56	94.23	$C = 1, \gamma = 0.1$
优化参数(本文)	97.68	97.25	97.96	$C_{opt} = 32, \gamma_{opt} = 8$

从结果可以得出, 网格搜索结合 5 折交叉验证的参数优化方法, 在预设搜索空间 $2^{-5} \sim 2^5$ 内精准找到最优惩罚因子 C 与核参数 γ , 可以有效解决 SVM 模型过拟合/欠拟合问题: 惩罚因子 $C_{opt} = 32$ 提升了模型对线性不可分样本的拟合能力, 降低了异常心律的漏检率; 核参数 $\gamma_{opt} = 8$ 适配心电特征的高维分布, 增强了核函数的特征映射能力, 提升了特征空间的分类精度; 参数优化后, 模型准确率提升 3.88 个百分点, 灵敏度提升 4.69 个百分点, 充分验证了参数优化对算法性能的提升作用。

5.3.3. 嵌入式部署性能验证实验

将优化后的 RBF-SVM 算法通过 C 语言移植到 STM32F407 嵌入式平台, 测试平台在实时采集场景下的单帧心电信号识别耗时与模型占用存储资源, 验证算法的轻量化与实时性, 同时测试平台连续工作的分类准确率, 验证算法在嵌入式端的工程化可行性, 结果如表 3 所示。

Table 3. Performance results of embedded platform deployment**表 3.** 嵌入式平台部署性能结果

指标	测试结果
嵌入式端分类准确率	97.21%
单帧信号识别耗时	2.3 ms
模型占用 Flash 空间	14.8 KB
模型占用 RAM 空间	8.5 KB
连续工作功耗	12 mA (3.3 V)

由结果可知: 嵌入式端分类准确率为 97.21%, 与 PC 端的 97.68% 仅相差 0.47 个百分点, 误差源于定点运算对浮点运算的近似, 完全满足临床便携式监测的精度需求; 单帧信号识别耗时仅 2.3 ms, 远低于心电信号采样频率(360 Hz, 单帧采样间隔约 2.78 ms), 实现实时在线识别; 模型占用存储资源极小 Flash 与 RAM 占用均在 15 KB 以内, 适配 STM32F407 的存储资源, 且连续工作功耗仅 12 mA, 满足便携式设备的低功耗需求。

实验结果表明, 所提算法可成功移植到嵌入式平台, 实现心电信号的实时、低功耗、高精度分类, 为便携式心电监测设备提供了可行的算法方案。

5.3.4. 算法鲁棒性验证实验

在 MIT-BIH 测试集中添加 SNR = 5 dB、10 dB、15 dB 的高斯噪声与肌电噪声, 构建低信噪比测试子集, 测试所提算法在不同信噪比下的 Acc、Se、Sp 指标, 同时与 1D-CNN、未优化 SVM 对比, 验证算法在噪声干扰下的鲁棒性。表 4 为各算法在不同信噪比下的准确率对比结果, 可以看出, 本文所提优化 RBF-SVM 算法在低信噪比场景下的鲁棒性显著优于 1D-CNN 与未优化 SVM。

Table 4. Comparison of accuracy of different algorithms under different signal-to-noise ratios (%)**表 4.** 不同信噪比下各算法准确率对比(%)

信噪比(SNR)	未优化 SVM	1D-CNN	优化 RBF-SVM
15 dB	91.25	96.32	96.87
10 dB	85.68	90.15	94.23
5 dB	78.32	82.56	89.76

同时还可以分析出,随着信噪比降低,各算法的准确率均呈下降趋势,但本文算法的下降幅度最小,在 SNR = 5dB 的强噪声场景下,准确率仍保持在 89% 以上,大幅高于其他对比算法;所提算法的高鲁棒性源于小波去噪 + 基线校正的双层预处理链路,db4 小波基可有效滤除高频噪声,平滑拟合法可消除基线漂移,即使在低信噪比场景下,仍能保留心电信号的核心特征;1D-CNN 因未充分优化预处理流程,在低信噪比下特征提取能力大幅下降,准确率下降明显;未优化 SVM 不仅缺乏有效的预处理,且参数未适配噪声场景,鲁棒性最差。

综上所述,所提算法在噪声干扰下仍能保持较高的分类精度,适配便携式心电监测设备在复杂环境下的信号采集需求。

5.4. 实验结论

通过多组对比实验与鲁棒性验证,可得出以下实验结论:

(1) 所提基于优化 RBF-SVM 的心律失常识别算法,在 MIT-BIH 数据库上的准确率、灵敏度、特异性均优于传统机器学习方法,分类性能接近深度学习方法,且模型体量远小于深度学习模型,实现了性能与轻量化的平衡;

(2) 网格搜索结合 5 折交叉验证的参数优化方法可有效提升 SVM 模型的分类性能,小波去噪与基线校正的预处理链路大幅增强了算法的噪声鲁棒性,是算法性能提升的两大核心因素;

(3) 算法可成功移植到 STM32F407 等嵌入式平台,在嵌入式端实现了毫秒级实时识别、低功耗连续工作、高精度分类,完全满足便携式心电监测设备的工程化需求;

(4) 算法在低信噪比场景下仍保持较高的分类精度,适配临床复杂的信号采集环境,为远程医疗系统的心电异常自动识别提供了可靠的算法支撑。

参考文献

- [1] 李恩泽,王珏,何柳,马长生.人工智能在心律失常领域中的应用进展[J].中国实用内科杂志,2024,44(2):89-91+108.
- [2] 李嘉,杨晓玲,张阳.心律失常自动分类算法研究现状综述[J].科技与创新,2019(18):47-48.
- [3] 杨枢,朱超.基于模糊隶属度与支持向量机心律失常分类模型[J].蚌埠医学院学报,2012,37(8):985-987+992.
- [4] 刘光达,周葛,董梦坤,胡新蕾,蔡靖,倪维广.基于 FFNN 和 1D-CNN 的实时心律失常诊断系统与算法[J].电子测量与仪器学报,2021,35(3):35-42.
- [5] 李雪.基于 LSTM 的心律失常分类研究[D]:[硕士学位论文].兰州:兰州大学:2018.
- [6] 赵勇,洪文学,孙士博.基于多特征和支持向量机的心律失常分类[J].生物医学工程学杂志,2011,28(2):292-295.
- [7] 李兴秀,唐建军,华晶.结合 CNN 与双向 LSTM 的心律失常分类[J].计算机科学与探索,2021,15(12):2353-2361.
- [8] 熊磊,何培宇,方安成,秦雷亮,潘帆.基于残差-注意力和 LSTM 的心律失常心拍分类方法研究[J].成都信息工

程大学学报, 2022, 37(2): 119-124.

- [9] 巴雨静, 高邵晨. 关于可穿戴心电设备和室性心律失常检测算法的研究综述[J]. 信息与电脑, 2026, 38(4): 94-96.
- [10] 朱晚婷, 范平. 可穿戴心电设备在心律失常诊断中的应用进展[J]. 实用心电学杂志, 2022, 31(3): 180-183.