

doi: 10.3969/j.issn.0490-6756.2020.02.015

# 基于三域特征提取和 GS-SVM 的 ECG 信号智能分类技术研究

方红伟, 赵 涛, 佃松宜

(四川大学电气工程学院, 成都 610065)

**摘要:** 近年来, 基于单域的特征提取方法已经得到广泛的研究, 并被用于心律失常的检测分类. 事实上, 多域特征提取在其分类中往往表现得更好. 本文利用 MIT/BIH 心律失常数据库中的 48 组 ECG 信号进行预处理, 从时域、频域和小波域提取了信号的三域特征, 这些特征从各个方面充分表征了 ECG 信号的性质. 再利用基于网格搜索的 SVM 结合归一化特征可将 ECG 信号划分为常见的 4 类. 该方法的总体精度达到 98.01%,  $f_1$  分值为 0.9800, 对 ECG 信号的检测性能良好, 相对目前绝大多数 ECG 信号分类器具有更强的泛化能力.

**关键词:** 心律失常检测; ECG 信号分类; 三域特征提取; 信号预处理; 基于网格搜索的 SVM  
**中图分类号:** TP391      **文献标识码:** A      **文章编号:** 0490-6756(2020)02-0297-07

## Research on intelligent classification of ECG signals based on three-domain features extraction and GS-SVM

FANG Hong-Wei, ZHAO Tao, DIAN Song-Yi

(College of Electrical Engineering, Sichuan University, Chengdu 610065, China)

**Abstract:** Single-domain based feature extraction has been extensively studied and is used to detect and classify Arrhythmia recently. In fact, multi-domain feature extraction tends to perform better in classification. In this paper, three-domain features are extracted from time-domain, frequency-domain and wavelet-domain using pre-processed ECG signals taken from 48 data sets in MIT/BIH arrhythmia database. These features fully characterize the nature of the ECG signals from various aspects. In the final stage, ECG signals are classified into four classes by the normalized features combined with grid-search based SVM, the overall accuracy and F1 score of the proposed method is 98.01% and 0.9800 respectively, it performs well in detection and classification of ECG signals and has better generalization against the most results reported so far.

**Keywords:** Arrhythmia detection; ECG signal classification; Three-domain features extraction; Signal preprocessing; Grid search based SVM

## 1 引言

心电图(Electrocardiogram, ECG)是医生诊断

患者是否患有心脏病的关键, 一个完整的心跳包括 P、Q、R、S、T 和 U 波等几部分, 它们都反映一定的生理信息. 医生可以根据各部分的波形异常来判断

收稿日期: 2019-03-22

基金项目: 国家自然科学基金(61703291); 四川省科技厅应用基础研究项目(2016JY0085)

作者简介: 方红伟(1994-), 男, 湖北枝江人, 硕士生, 研究方向为机器学习与智能控制. E-mail: 873358193@qq.com

通讯作者: 佃松宜. E-mail: scudiansy@scu.edu.cn

一个人是否生病. 医生对 ECG 的解读往往是基于经验的, 他们的判断依赖于 ECG 信号中基于时域的一些病因的描述, 实际上除了时域, 还可以从其他域如频域、小波域等去诊断 ECG 信号. 为了帮助医生快速做出判断, 提高患者的就诊效率, 本文对 ECG 信号的智能分类技术进行了研究.

ECG 信号的分类是模式识别中的一个很好的课题, 许多学者对此进行了研究. 对于原始 ECG 信号, 已有学者采用小波变换<sup>[1-2]</sup>, 中值滤波和陷波滤波器<sup>[3]</sup>, 稀疏导数分解<sup>[4]</sup>等方法去噪, 但这些方法往往不能同时去除工频干扰, 基线漂移, 肌电干扰等噪声. 去噪后的信号用于提取特征, 有学者用时域特征分析<sup>[1,5]</sup>, 频域及时频域特征分析<sup>[4]</sup>, 小波域特征分析<sup>[2,3,6]</sup>, 主成分分析(Principal Component Analysis, PCA)<sup>[1,7]</sup>及独立主成分分析(Independent Principal Component Analysis, ICA)<sup>[7]</sup>等方法. 然而, 这些方法提取的特征比较片面, 不能全面的表达 ECG 信号. 特征提取的目的是为了更好地将 ECG 信号分类, 常用的方法有支持向量机(Support Vector Machine, SVM)<sup>[1,2,5,7-9]</sup>, 随机森林<sup>[4]</sup>, 神经网络<sup>[6]</sup>, 深度置信网络和主动学习<sup>[9]</sup>等, 但是对于一种分类方法, 如何选择合适的参数或学习框架以达到最好的分类效果也是一个难题.

本文采用连续小波变换(Continuous Wavelet Transform, CWT)对原始 ECG 信号进行预处理, 可同时去除各种干扰. 然后从时域、频域和小波域中分别提取特征, 把这些特征归一化后结合 GS-SVM(基于网格搜索的 SVM)对 ECG 信号进行分类. 最后用基于混淆矩阵的评价指标来评价算法的性能.

## 2 提出的方法

本文提出的 ECG 信号检测方法主要包括 ECG 信号的获取、预处理及分割、特征提取和归一化, 最后采用 GS-SVM 进行分类. 整个流程图如图 1 所示.

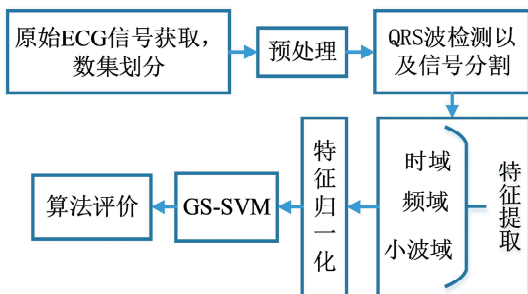


图 1 ECG 信号分类流程

Fig. 1 The process of ECG signal classification

### 2.1 数据获取及预处理

本文的数据来源于 MIT/BIH 的心律失常数据库. 该数据库包含 48 组 30 min ECG 信号, ECG 数据采样频率为 360 Hz. 每组数据都从两个引导通道收集. 读取 48 组 ECG 数据, 选择合适的数据量进行研究. 标定正常—N; 左束支传导阻滞—L; 右束支传导阻滞—R; 所有其他 ECG 信号类型为“其他”—“O”, 数据集划分如表 1 所示.

表 1 MIT/BIH 数据库中数据集划分  
Tab. 1 Data division in MIT/BIH database

心律类型	MIT-BIH 中心拍总数 / 选取心拍数	训练集	测试集
N	75 016/10 016	7 011	3 005
L	8 072/8 072	5 650	2 422
R	7 255/7 255	5 079	2 177
“O”	19 911/9 911	6 938	2 973
总数	35 255	24 678	10 577

直接从 MIT-BIH 心律失常数据库中获取的原始 ECG 信号, 存在电力线频率干扰、基线漂移、肌电图干扰等不可忽略的干扰因素, 需要进行预处理. 采用 CWT 对原始信号进行去噪<sup>[10]</sup> 预处理, CWT 的实质是对 ECG 原始信号的滤波, 对于有限能量信号  $f(t)$ , 其基于母波  $\Psi$  的 CWT 可表示为

$$(W_{\Psi}f)(a, b) = |a|^{-1/2} \int_{-\infty}^{+\infty} f(t) \overline{\Psi\left(\frac{t-b}{a}\right)} dt \quad (1)$$

其中,  $a \in R^+$  为缩放因子;  $b \in R$ , 为平移因子. 本文选用墨西哥草帽函数为母波, 其定义为

$$\psi(x) = \frac{2}{\sqrt{3}} \pi^{-1/4} (1-x^2) e^{-x^2/2} \quad (2)$$

墨西哥草帽函数无限光滑即无穷次可微, 因此它不对单独的噪声点敏感<sup>[11]</sup>, 而其独特的时域特性, 使得 ECG 信号的 Q、R、S 等特征点突出. 由图 2 可以看出, 图 2(a) 中 ECG 信号在处理前存在严重的基线漂移和一定的干扰. 图 2(b) 中处理后的 ECG 信号基与零纵轴对齐, ECG 图像变得更加平滑, 处理后的信号便于进一步处理和分析.

接下来, 本文采用 Pan 和 Tompkins 提出的实时 QRS 波检测算法<sup>[12]</sup> 来检测 ECG 信号中的 QRS 波. 该算法对 MIT/BIH 异常心律数据的检测准确率达到 99.3%. 一个心拍周期的主要能量集中在 QRS 段, 通过分割心拍可以去除冗余信息. 检测到 R 峰值后, 取 R 峰值前 25 点和 R 峰值后 44 点的

数据,共 70 点数据片段代替一个心拍周期信号。




图 2 原始 ECG 信号和预处理过 ECG 信号

Fig. 2 Raw ECG signals and pre-processed ECG signals

## 2.2 特征提取

将 ECG 信号的特征从时域、频域和小波域中提取出来,从各个域获取信号特征,以便准确分类。

(1) 时域特征. 不同类型的 ECG 信号在直观的波形上有一定的差异,可以从其波形中提取一些形态特征. 对于每个信号段  $x_n$ , 其 R 峰振幅作为振幅特征。

$$Amp_n = \text{Max}(x_n) \quad (3)$$

每个信号段的标准差  $\sigma_n$  反映了信号在均值附近的波动程度。

$$\sigma_n = \sqrt{\frac{1}{L} \sum_i^L (x_n(i) - \mu)^2} \quad (4)$$

其中,  $\mu$  表示信号段均值。

峰值因子  $CF_n$  表示峰值与有效值的比值。

$$CF_n = \frac{|\text{peak}(x_n)|}{\text{RMS}(x_n)} \quad (5)$$

其中,  $\text{RMS}(x_n)$  表示信号段的均方根;  $\text{peak}(x_n)$  是信号段的峰值。

形状因子  $SF_n$  是一种受物体形状影响,但不受其维度影响的值。

$$SF_n = \frac{\text{RMS}(x_n)}{\text{Mean}(|x_n|)} \quad (6)$$

其中,  $\text{Mean}(|x_n|)$  是信号段的幅值均值。

脉冲因子  $IF_n$ , 其表示波形的冲击程度,对 R 波形的检测比较敏感。

$$IF_n = \frac{\text{peak}(x_n)}{\text{Mean}(|x_n|)} \quad (7)$$

(2) 频域特征. 为了提取 ECG 信号的频域特征,首先对 ECG 信号进行快速离散傅里叶变换 (Fast Fourier Transform, FFT). FFT 是离散傅里叶变换 (Design for Testability, DFT) 的快速算法,对于 ECG 信号片段  $x_n(i)$ ,  $i = 1, 2, \dots, 70$ , 其 FFT 可表示为

$$X_n(m) = \sum_i^L x_n(i) W_L^{(i-1)(m-1)} \quad (8)$$

其中,  $W_L = e^{-2\pi M}$ ,  $X_n(m)$  是 ECG 信号片段的频域表达式,其中  $m = 1, 2, \dots, L$ , 表示谱线数。

在频域信息中,可以得到频率与幅值之间的关系. 在频域中, QRS 波位于高频区,而 P 波和 T 波位于低频区. 不同类型的 ECG 信号在频率分量上存在较大差异. 根据高频和低频的幅值差,选择了能够反映这些幅值差的一些特征. 本文选取频谱均值、频谱标准差、频谱偏度和频谱峰度作为频域的 4 个特征。

频谱均值  $SM_n$  为频率幅值谱的平均值。

$$SM_n = \frac{1}{L} \sum_m^L X_n(m) \quad (9)$$

频谱标准差  $SSD_n$  表示信号在均值周围波动的程度。

$$SSD_n = \sqrt{\frac{1}{L-1} \sum_m^L (X_n(m) - SM_n)^2} \quad (10)$$

频谱偏度  $SD_n$  和频谱峭度  $SK_n$  是从概率论和统计学角度定义的波形分布概率的描述式。

$$SD_n = \frac{1}{L} \frac{\sum_m^L (X_n(m) - SM_n)^3}{(SSD_n)^{\frac{3}{2}}} \quad (11)$$

$$SK_n = \frac{1}{L} \frac{\sum_m^L (X_n(m) - SM_n)^4}{SSD_n^2} \quad (12)$$

(3) 小波域特征. 当被观测对象是具有多个动作电位的重复信号时,如 ECG 信号,小波域特征可以识别高频信号的相对分布<sup>[13]</sup>. 本文采用小波包分解 (WPD) 对 ECG 信号进行小波域分析. WPD 是离散小波变换 (DWT) 的经典推广,它将频带划分为若干层,并对一般小波分析中未细分的高频部分进行分解. 图 3 为三层小波包分解树示意图. S 表示分解前的原始信号; A 表示分解后的高频信号; D 表示分解后的低频信号,脚标表示分解的层数。




图 3 3层小波包分解树

Fig. 3 Three-level wavelet packet decomposition tree.

本文选取“Shannon”熵类型,以“db6”为母波,对 ECG 信号进行四级分解<sup>[3]</sup>.通过计算第四层小波包系数的奇异值、标准差和最大值<sup>[14]</sup>,可以得到三种小波域特征信息.由于第四层有 16 个频段,总共可以得到 48 个特征.设第四层分解得到的系数为  $\zeta_i, i=1,2,\dots,16$ .

奇异值  $SVD_n$  反映了矩阵的固有特性,在信号处理、统计等领域有着重要的应用.奇异值具有良好的稳定性,它不会随着矩阵元素的微小变化而发生剧烈的变化.对于同一种 ECG 信号,其奇异值具有很高的相似性,很容易区分不同类型的心律.

$$SVD_n = \text{svd} [\zeta_1, \zeta_2, \dots, \zeta_{16}]_n \quad (13)$$

最大值  $MAX_n$  是从第 4 层分解系数中直接选取的最大值.

$$MAX_n = \max [\zeta_1, \zeta_2, \dots, \zeta_{16}]_n \quad (14)$$

标准差  $STD_n$  来描述第 4 层分解系数的离散程度.

$$STD_n = \text{std} [\zeta_1, \zeta_2, \dots, \zeta_{16}]_n \quad (15)$$

综上所述,表 2 列出了从 3 个域中提取的所有特征.

表 2 从时域、频域、小波域提取的特征

Tab. 2 All features extracted from t-domain, f-domain, w-domain

特征种类	特征名	表达式
时域特征	幅值	$f_1 = Amp_n$
	标准差	$f_2 = \sigma_n$
	峰值因子	$f_3 = CF_n$
	形状因子	$f_4 = SF_n$
	脉冲因子	$f_5 = IF_n$
频域特征	频率均值	$f_6 = SM_n$
	频率标准差	$f_7 = SSD_n$
	频率偏度	$f_8 = SD_n$
	频率峭度	$f_9 = SK_n$
	小波域特征	奇异值
最大值		$f_{16} \sim f_{31} = MAX_n$
标准差		$f_{32} \sim f_{57} = STD_n$

## 2.3 特征归一化

特征值之间差异很大,如果将这些特征直接输入到经典算法中,算法的权值在收敛过程中会发生振荡,容易收敛到局部最优结果.为了避免这种情况,将采用以下方法进行归一化.

$$F_j = \frac{f_j - \bar{f}_j}{\max(f_j) - \min(f_j)} \quad (16)$$

其中,  $j=1,2,3,\dots,57$ . 处理后的特征值在  $-1 \sim 1$  范围内,这将大大提高学习算法的收敛能力.

## 2.4 GS-SVM

虽然 SVM 已成功地应用于 ECG 信号检测,但如何选择最优参数一直是一个难题.对于给定的训练集  $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ ,  $y_i \in \{-1, 1\}, i=1,2,3,\dots,n$ ,其中,  $x_n$  是输入,  $y_n$  是对应的输出, SVM 满足如下表达式<sup>[15-17]</sup>.

$$\begin{aligned} \min_{w, b, \zeta} & \frac{1}{2} w^T w + C \sum_{i=1}^l \zeta_i \\ \text{subject to} & y_i (w^T \Psi(x_i) + b) \geq \\ & 1 - \zeta_i, \zeta_i \geq 0. \end{aligned} \quad (17)$$

其中,  $\Psi(x_i)$  函数将  $x_i$  映射到一个更高维的空间,  $C > 0$  是误差项的惩罚因子. SVM 目的是在高维空间中找到一个边界最大的线性划分超平面  $w^T x_i + b = 0$ . 在本文中, RBF 核 ( $k(x_i, x_k) = \exp(-\lambda \|x_i - x_k\|^2)$ ) 作为核函数,其中,  $\lambda$  为核函数参数. 对于整个算法,惩罚因子  $C$  和核函数参数  $\lambda$  的选取决定着算法的性能,为了获取最优参数,本文运用网格搜索法(GS)<sup>[18]</sup>来获取最优参数,可以同时对于  $C$  与  $\lambda$  搜索,搜索过程中它们相互独立,能使算法达到全局最优. GS-SVM 的流程如下所示.

**步骤 1:** 选择测试集与训练集.

**步骤 2:** 粗略选取能决定  $C$  与  $\lambda$  搜索范围的两个参数  $\beta \in [\beta_{\min}, \beta_{\max}]$  和  $\epsilon \in [\epsilon_{\min}, \epsilon_{\max}]$ ,  $\beta$  和  $\epsilon$  为在各自固定步长下的取值.

**步骤 3:** 设定  $C$  与  $\lambda$  的取值步长分别为  $a$  和  $b$ , 计算  $C$  与  $\lambda$  每一次的搜索值  $P_k = (C = 2^{\beta_i}, \lambda = 2^{\epsilon_j})$  其中,  $i = 1, 2, \dots, \lfloor (\beta_{\max} - \beta_{\min})/a \rfloor, j = 1, 2, \dots, \lfloor (\epsilon_{\max} - \epsilon_{\min})/a \rfloor, k = 1, 2, \dots, \lfloor (\beta_{\max} - \beta_{\min})/a \rfloor * \lfloor (\epsilon_{\max} - \epsilon_{\min})/a \rfloor$ .

**步骤 4:** 将 SVM 中  $C$  与  $\lambda$  参数设置为  $P_k$ , 结合训练集对 SVM 进行训练,利用测试集输出得到分类正确率,将最高正确率对应的  $P_k$  记录下来.

**步骤 5:** 搜索结束时,如果最高正确率对应的  $P_k$  不落在由  $C$  与  $\lambda$  搜索范围组成的网格边界上,此时则得到了最优的  $C$  与  $\lambda$ , 算法结束;否则要重

新选定  $\sigma$  和  $\varepsilon$ , 确保搜索结束时  $P_k$  落在网格边界内, 回到步骤 3.

### 3 仿真与性能评价

#### 3.1 性能评价指标

混淆矩阵常用于表示分类的结果, 从中可以知道有多少样品是正确分类的及一些其他的细节. 表 3 为 ECG 信号分类的混淆矩阵.

表 3 混淆矩阵  
Tab. 3 Confusion matrix

类型	正确分类	错误分类
某种类型	真阳性(TP)	假阴性(FN)
其他类型	假阳性(FP)	真阴性(TN)

根据混淆矩阵, 列出 7 个评价指标如表 4 所示, 用来评估分类器性能.

表 4 评价指标  
Tab. 4 The table of evaluation indicators

评价指标	表达式
整体正确率(OA)	$OA = \frac{TP+TN}{TP+TN+FP+FN}$
整体错误率(OE)	$OE = \frac{FP+FN}{TP+TN+FP+FN}$
真阴性比率(SPC)	$SPC = \frac{TN}{TN+FP}$
召回率(REC)	$REC = \frac{TP}{TP+FN}$
精准率(PRE)	$PRE = \frac{TP}{TP+FP}$
阴性预测值(NPV)	$NPV = \frac{TN}{TN+FN}$
$F_1$ 分值	$F_1 \text{ score} = \frac{2 \times REC \times PRE}{REC + PRE}$

#### 3.2 仿真结果与分析

GS-SVM 结合三域特征的 ECG 信号分类算法是在 Matlab 平台上实现的. 利用训练集训练 SVM





图 4 搜索最优  $C$  与  $\lambda$  的三维网格

Fig. 4 Three-dimensional grid graph of searching the optimal  $C$  and  $\lambda$

分类器, 通过测试集输出分类器的准确率, 整个参数搜索过程可以用图 4 中的三维网格图表示. 网格处的红点位置标记着最高分类准确率, 同时也对应着最优的  $C$  与  $\lambda$ .

为了探索不同域的特征对分类结果的影响, 利用每一类特征、每两类特征和所有三类特征分别结合 GS-SVM 对 ECG 信号进行分类, 以获得分类准确率和特征种类关系的折线图如图 5 所示, 图中  $f_t$ 、 $f_f$ 、 $f_w$  分别表示提取自时域、频域、小波域的特征. 由折线图可知, 如果仅利用一种特征来对 ECG 信号分类, 小波域特征的效果最好, 这是因为它对 ECG 信号的解释最为细致. 时域特征有着最差的效果, 这也解释着医生如果仅凭时域经验准则来分析 ECG 信号, 结果可能会出现较大的偏差. 但是对于分类器而言, 时域信号对于提升 ECG 信号分类正确率还是有一定的帮助.

将测试集输入到最优参数配置的 SVM 中, 得到表 5 所示的混淆矩阵. 该矩阵详细的展示了 4 类 ECG 信号的分类情况.



—○—	$f_w$	96.55	$f_w+f_t$	97.23	$f_w+f_t+f_f$	98.01
—□—	$f_t$	92.12	$f_t+f_f$	96.41	$f_t+f_f+f_w$	98.01
—△—	$f_f$	79.11	$f_w+f_w$	97.10	$f_f+f_w+f_t$	98.01

图 5 三类特征对分类器的影响

Fig. 5 Effect of three types of features on classifier

表 5 提出的方法的混淆矩阵

Tab. 5 Confusion matrix of proposed method

注释类别	预测类别				总数
	N	L	R	“O”	
N	2989	3	1	33	3 026
L	1	2 402	0	25	2 428
R	0	0	2 120	60	2 180
“O”	15	17	56	2 855	2 943
总数	3 005	2 422	2 177	2 973	10 577

基于混淆矩阵,计算各性能评价参数如表 6 所示. SPC、REC、PRE、NPV 分别表示每一种 ECG 信号的分类效果,例如 REC 表示该种信号 TP 的

占有率,也表示其召回率. OA、OE 和  $F_1$  分数是分类器的总体评价,例如  $F_1$  分数是 REC 和 PRE 的调和平均值,越接近 1,就表示分类器效果越好.

表 6 每个类别的性能评估

Tab. 6 Performance evaluation of each class

类别	所有数据集				测试集			
	N	L	R	"O"	N	L	R	"O"
SPC/%	98.26	98.25	98.79	98.77	97.70	97.73	98.20	98.39
REC/%	99.17	99.43	97.48	97.87	98.78	98.93	97.25	97.01
PRE/%	99.78	99.67	97.71	96.90	99.47	99.17	97.38	96.03
NPV/%	98.02	98.18	98.73	99.15	97.43	97.66	98.17	98.78
OA/%		98.52				98.01		
OE/%		1.48				1.99		
$F_1$ score		0.985 0				0.980 0		

### 3.3 结果比较

表 7 给出了本文方法与其他文献中方法的 ECG 信号分类结果对比. 在文献[7]中,用主成分分析(PCA)和核独立成分分析(KICA)特征提取 ECG 信号特征,再采用基于遗传算法优化的 SVM 算法(GA-SVM)将 ECG 信号分为了 5 类,其准确率为 97.78%,但样本仅为 720 个心拍;在文献[2]中,用 Hermit 函数对 ECG 信号进行变换,提取系数再结合一些时域特征作为总的特征,利用基于粒子群算法优化的块神经网络(PSO-BBNN),将 ECG 信号分为 5 类,分类正确率为 97%;在文献[19,20]中,提取了 ECG 信号的时间域波形间隔特征和纹理特征,利用基于遗传蝙蝠优化算法的支持向量神经网络(GB-SVNN),将 ECG 信号分为心律失常或无心律失常信号,其准确率为 96.96%;在文献[1]中,从 ECG 信号中提取了高阶谱(HOS)特征,然后经过 PCA 降维,最后利用最小

二乘支持向量机(LS-SVM)将 ECG 信号分为 5 类,准确率为 93.48%;在文献[6]中,利用 WPD 结合统计方法提取特征,利用基于遗传算法的 BP 神经网络(GA-BPNN)将 ECG 信号分为了 6 类,得到了 97.78%的正确率,但仿真中仅用到 300 个实验数据. 在文献[20]中,研究了三种监督分类算法,多层感知器(MLP),SVM 以及径向基函数和概率神经网络(RBFNN,PNN)对 ECG 信号分类的效果,结合基于形态学和时间序列的时域特征,将 ECG 信号分为 3 类,分类精度最高为 97.14%. 其中,文献[6-7]里的实验数据不够多,得到的分类器不能认为具有较好的泛化能力和鲁棒性. 本文提出的方法对 ECG 信号三域特征进行了研究,利用 GS-SVM 对 MIT/BIH 中 48 个文件的 ECG 信号分类,得到准确率为 98.02%,该方法取得较高的准确性,较多的实验数据也保证了分类器的泛化能力和鲁棒性.

表 7 与其他文献结果对比

Tab. 7 Comparison with other literatures

文献	方法	特征	分类数	准确率/%
Li <i>et al</i> <sup>[7]</sup>	GA-SVM	PCA + KICA	5	97.78
Zadeh <i>et al</i> <sup>[2]</sup>	PSO-BBNN	Hermit 系数+时域特征	5	97.00
Bhagyalakshmi <i>et al</i> <sup>[19]</sup>	GB-SVNN	时域特征+纹理特征	2	96.96
Martis <i>et al</i> <sup>[1]</sup>	LS-SVM	HOS+PCA	5	93.48
Li <i>et al</i> [6]	GA-BPNN	小波包特征	6	97.78
Zadeh <i>et al</i> <sup>[20]</sup>	SVM	时域特征	3	97.14
本文	GS-SVM	三域特征	4	98.01

## 4 结 论

本文提出了一种基于三域特征提取和 GS-SVM 的 ECG 信号检测方法. 时域特征是 ECG 信号基于时间序列的形态学描述; 频域特征描述 ECG 信号的频率统计学特征; 小波域特征是低频和低频中没有反映出来的细节信息. ECG 信号可被这些特征充分地表示, 将 GS-SVM 与这些特征相结合, 实现了 ECG 信号的智能分类, 该方法可以有效地帮助医生对患者进行诊断.

### 参考文献:

- [1] Martis R J, Acharya U R, Mandana K M, *et al.* Cardiac decision making using higher order spectra [J]. *Biomed Signal Proces*, 2013, 8: 193.
- [2] Shadmand S, Mashoufi B. A new personalized ECG signal classification algorithm using block-based neural network and particle swarm optimization [J]. *Biomed Signal Proces*, 2016, 11: 25.
- [3] Kutlu Y, Kuntalp D. Feature extraction for ECG heartbeats using higher order statistics of WPD coefficients [J]. *Comput Meth Prog Bio*, 2012, 105: 257.
- [4] Zabihi M, Rad A B, Katsaggelos A K, *et al.* Detection of atrial fibrillation in ECG hand-held devices using a random forest classifier [C]. Rennes, Franc; IEEE, Computing in Cardiology, 2018.
- [5] Athif M, Yasawardene P C, Daluwatte C. Detecting atrial fibrillation from short single lead ECGs using statistical and morphological features [J]. *Physiol Meas*, 2018, 39: 1.
- [6] Li H, Yuan D, Ma X, *et al.* Genetic algorithm for the optimization of features and neural networks in ECG signals classification [J]. *Sci Rep*, 2017, 7: 41011.
- [7] Li H, Liang H, Cao L, *et al.* Novel ECG signal classification based on KICA nonlinear feature extraction [J]. *Circ Syst Signal Pr*, 2016, 35: 1187.
- [8] Bulusu S C, Faezipour M, Ng V, *et al.* Transient ST-segment episode detection for ECG beat classification [C]//Proceedings of the Life Science Systems & Applications Workshop. Bethesda, MD, USA; IEEE, 2011.
- [9] Sayantan G, Kien P T, Kadambari K V. Classification of ECG beats using deep belief network and active learning [J]. *Med Biol Engineering Comput*, 2018, 1: 1.
- [10] 杨健, 杨超宇, 李慧宗. 基于二维离散小波的生成图像鉴别方法 [J]. *吉林大学学报: 理学版*, 2019, 57: 619.
- [11] 蒋腾, 胡涛, 祝民鹏, 等. 基于连续小波变换的多数据心率提取方法 [J]. *现代雷达*, 2019, 41: 22.
- [12] Pan J, Tompkins W J. A real-time QRS detection algorithm [J]. *IEEE T Bio Eng*, 2007, 32: 230.
- [13] Najarian K, Splinter R. *Biomedical Signal and Image Processing* [M]. 2nd Ed. Florida; CRC Press, 2012.
- [14] 袁丹阳. 基于小波包和神经网络的心电信号分类方法研究 [D]. 天津: 天津工业大学, 2017.
- [15] 秦璐, 李旭伟. 基于区域标记法的代价敏感支持向量机在股票预测中的研究 [J]. *四川大学学报: 自然科学版*, 2018, 55: 277.
- [16] 贺紫平, 夏克文, 潘用科, 等. 分支定界半监督 SVM 在油层识别中的应用 [J]. *重庆邮电大学学报: 自然科学版*, 2019, 31: 563.
- [17] 彭晓冰, 李启顺, 王丽珍, 等. 面向 SVM 的隐私保护方法研究进展 [J]. *江苏大学学报: 自然科学版*, 2017, 38: 78.
- [18] 王健峰, 张磊, 陈国兴, 等. 基于改进的网格搜索法的 SVM 参数优化 [J]. *应用科技*, 2012, 39: 28.
- [19] Bhagyalakshmi V, Pujeri R V, Devanagavi G D. GB-SVNN: Genetic BAT assisted support vector neural network for arrhythmia classification using ECG signals [J]. *J King Saud Univ: Comput Inform Sci*, 2018, 2018: S1319157817302823.
- [20] Zadeh A E, Khazaei A, Ranee V. Classification of the electrocardiogram signals using supervised classifiers and efficient features [J]. *Comput Method Prog Bio*, 2010, 99: 179.

### 引用本文格式:

中文: 方红伟, 赵涛, 佃松宜. 基于三域特征提取和 GS-SVM 的 ECG 信号智能分类技术研究 [J]. *四川大学学报: 自然科学版*, 2020, 57: 297.

英文: Fang H W, Zhao T, Dian S Y. Research on intelligent classification of ECG signals based on three-domain features extraction and GS-SVM [J]. *J Sichuan Univ: Nat Sci Ed*, 2020, 57: 297.