

基于级联分类器的心律失常检测

张翊丹, 刘文涵, 张梦新, 廖远, 黄启俊, 常胜, 王豪, 何进
武汉大学物理科学与技术学院, 湖北 武汉 430000

【摘要】常见的心律失常如室性早搏(PVC)和左束支传导阻滞(LBBB)在心血管疾病诊断和预后中具有重要的临床价值。本文提出一种用于PVC和LBBB自动检测的级联分类器,通过提取时域和形态特征,采用支持向量机区分PVC和非PVC,再采用加权最小距离分类器(W-MDC)将非PVC分为正常(N)和LBBB。用MIT-BIH心律失常数据库进行算法验证,对N、LBBB和PVC三分类的总体正确率为96.28%,N、LBBB、PVC各类的灵敏度和特异性分别为98.59%、97.15%、81.41%、91.89%和89.22%、84.87%,验证该算法的泛化能力及对不同病人的心拍分类有效性。此外,本文还证明多导联信息综合对LBBB分类性能的提高。

【关键词】室性早搏;左束支传导阻滞;级联分类器;支持向量机;加权最小距离分类器

【中图分类号】TP391

【文献标志码】A

【文章编号】1005-202X(2018)08-0945-06

Arrhythmia detection based on Cascade classifier

ZHANG Yidan, LIU Wenhan, ZHANG Mengxin, LIAO Yuan, HUANG Qijun, CHANG Sheng, WANG Hao, HE Jin
School of Physics and Technology, Wuhan University, Wuhan 430000, China

Abstract: As common cardiac arrhythmias, premature ventricular contraction (PVC) and left bundle branch block (LBBB) have great significance in the diagnosis and prognosis of cardiovascular diseases. For the automatic detection of PVC and LBBB is proposed. By extracting the time-domain and morphological features, support vector machine (SVM) is utilized to distinguish PVC and non-PVC. The labeled non-PVC is then divided into normal (N) and LBBB using weighted minimum distance classifier (W-MDC). The proposed algorithm is evaluated using MIT-BIH arrhythmia database. The overall accuracy of N, LBBB and PVC classification is 96.28%. The sensitivity and specificity are 98.59% and 97.15% for N class, 81.41% and 91.89% for LBBB, 89.22% and 84.87% for PVC, respectively, which inter-patient heartbeat classification and the generalization ability of the proposed algorithm among different individuals. In addition, the synthesis of multi-leads information is also proved to be able to improve the LBBB detection performance.

Keywords: premature ventricular contraction; left bundle branch block; Cascade classifier; support vector machine; weighted minimum distance classifier

前言

心血管疾病具有突发性以及致死致残率高的特点,据世界卫生组织报道,心血管疾病已成为全球非传染性疾病致死的首要原因,对其尽早发现和介入治疗具有十分重要的临床价值^[1]。同时,研究表明大

多数心血管疾病患者在平时和发病前都会伴随一系列心律失常症状。作为临床上最为常用的心律失常诊断手段,心电图(ECG)具有波形复杂、数据量大的特点,根据ECG实现心律失常自动识别能够有效提高ECG识别的效率,同时有利于实现对病人的实时监护,因此ECG自动分析和心律失常自动检测技术一直是广大科研工作者研究的重点。

室性早搏(PVC)作为最为常见的心律失常之一,常被认为是一种“良性”的心律失常,但频繁出现的PVC常与各类心血管疾病(如心肌缺血、心肌梗死)有着紧密联系,同时,PVC具有显著的预后意义^[2]。左束支传导阻滞(LBBB)不同于PVC,常伴随器质性心脏病出现。最新研究表明,LBBB不仅是传导系统

【收稿日期】2018-02-27

【基金项目】湖北省自然科学基金面上项目(2017CFB660);中央高校基本科研业务专项经费(2042016kf0189)

【作者简介】张翊丹,硕士研究生,主要研究方向:心电信号自动识别算法研究,E-mail: yidan_zhang@whu.edu.cn

【通信作者】黄启俊,博士,教授,主要研究方向:微电子系统设计、探测系统(仪器)研发,E-mail:huangqj@whu.edu.cn

疾病,还可能是潜在心肌病的早期表现,并与伴随疾病的预后密切相关^[3-5]。因此,本文重点研究PVC和LBBB两种异常心拍的自动分类。

目前,心拍分类的主要技术手段通常是在心电信号时域和波形特征^[6-12]的基础上,结合小波变换^[13-15]、傅里叶变换^[15]、高阶统计量^[14, 16-17]等数理统计特征和主成分分析(PCA)^[18]、独立成分分析(ICA)^[19]等特征提取方法,采用各种模式识别分类器,如BP神经网络^[18-19]、支持向量机(SVM)^[17-18]、极限学习机(ELM)^[18]等对心拍进行分类。这些工作在测试集上取得了较好的分类效果,但绝大多数的工作在训练集和测试集中包含来自同一个体的ECG样本,没有考虑不同病人间心电信号的显著差异,这种分类被称为病人内的心拍分类。对此,De Chazal等^[11]提出一种病人间的心拍分类,即训练集和测试集的ECG样本所属个体没有交集。考虑到心律失常监护设备在实际应用中的用户差异,基于病人间的心拍识别具有更为显著的临床价值和更加优异的泛化能力。而多项研究结果表明,病人间的差异性大大超过病人内的差异性,病人内的心拍识别正确率要显著高于病人间的识别正确率^[11, 20-21]。此外,由于心电样本中,正常心拍的样本量远多于其他各种异常心拍样本,数据的不平衡增加了分类的难度,尤其是对于LBBB的分类。

因此,本文提出一种基于级联分类器的心律失常自动检测算法,考虑病人间的个体差异,实现病人间PVC和LBBB的自动分类。首先在R峰检测的基础上,提取每个心拍的形态特征和间期特征,通过SVM实现对PVC和非PVC的分类。再在SVM分类结果的基础上,将归一化后的二导联心电波形及间期、形态特征,输入到加权最小距离分类器(W-MDC)中,实现对LBBB的分类。该算法在MIT-BIH心律失常数据库上进行了测试,验证了该算法对于病人间的LBBB和PVC分类的有效性。

1 材料与方法

1.1 实验数据

本实验ECG数据来源于MIT-BIH心律失常数据库^[22]。该数据库包含48条心电图记录,取自于47位个体,并由两位心电专家进行注释,是国内外心电信号研究中最为常用的标准心电数据库之一。每条记录包含A、B两个通道,来自不同导联的信号,每条信号长约30 min,采样率为360 Hz。根据AAMI标准^[23],不考虑包含起搏心跳的4条记录:102、104、107和217。剩下的44条记录考虑到个体间的差异,按照

文献[11, 21]被分为训练集DS1和测试集DS2,此外,除LBBB和PVC外的其他心拍均被标记为正常心拍(N)。训练集以及测试集的组成见表1,可以看出数据集中样本数不平衡。

表1 训练集和测试集的心拍组成

Tab.1 Composition of heartbeats in training dataset and testing dataset

Dataset	N	LBBB	PVC	Total
DS1	43 329	3 946	3 680	50 955
DS2	42 308	4 120	3 218	49 646
Total	85 637	8 066	6 898	100 601

N: Normal; LBBB: Left bundle branch block; PVC: Premature ventricular contraction; Training dataset DS1 consisted of data from record 101, 106, 108, 109, 112, 114, 115, 116, 118, 119, 122, 124, 201, 203, 205, 207, 208, 209, 215, 220, 223 and 230. Testing dataset DS2 consisted of data from record 100, 103, 105, 111, 113, 117, 121, 123, 200, 202, 210, 212, 213, 214, 219, 221, 222, 228, 231, 232, 233 and 234. The 4 paced records (102, 104, 107 and 217) were not included. Besides, considering the feature extraction of heartbeat, the first two and last heartbeats of each record were excluded.

1.2 ECG信号的特征提取

在进行ECG信号特征提取之前,首先需要将ECG信号切分成心拍,心拍分割不是此次研究的重点,因此本研究直接根据MIT-BIH心律失常数据库中标记的R峰切分心拍。在R峰已知的基础上,基于Salih等^[24]的窗口搜索法实现QRS波起止点的检测以及T峰的检测。特征点检测完成后,进而进行ECG信号的特征提取。下面详细介绍本文用到的特征量。

1.2.1 时域间期特征 在心电图的临床医学诊断中,PVC的发生常伴随着不规则的RR间期(当前心拍的R峰到前一个心拍的R峰的时间间隔),LBBB则常表现为QRS波时限延长。为此,得到以下时域特征:(1)Pre_RR:前一个心拍的RR间期;(2)Cur_RR:当前心拍的RR间期;(3)Next_RR:下一个心拍的RR间期;(4)QRS_Width当前心拍的QRS波宽,QRS波宽定义为QRS波起点到QRS波终点的时间间隔。

1.2.2 形态特征 PVC在发生时,通常还表现出R峰高幅,ST段的方向与QRS波群主波方向相反的特点。LBBB的QRS波形态也常发生较大变化。为此,得到以下形态特征:(1)R_Amp:R峰的幅值;(2)QRS_Area:QRS波面积,由下式计算得到:

$$\text{QRS_Area} = \sum_{i=1}^M |X_i| \quad (1)$$

其中, X_i 是QRS波中第*i*个点对应的幅值, M 表示

QRS波的长度;(3)ST_Divation:ST-T段(QRS波终点到T峰)的偏移量,由下式计算得到:

$$ST_Divation = \sqrt{\frac{1}{K} \sum_{i=1}^K (X_i - \eta)^2} \quad (2)$$

其中, X_i 是ST-T段中第 i 个点对应的幅值, K 表示ST-T段的长度, η 表示ST-T段幅值的平均值;(4) Norm_Signal:取R峰前99个采样点,以及R峰后100个采样点,包括R峰在内200个采样点的幅值。为避免滤波器造成的失真,信号没有进行除归一化外的任何预处理。考虑到采集设备以及个体差异造成的幅值偏移,对该200个采样点的幅值进行归一化:

$$X_{\text{norm}} = \frac{X - \mu}{\delta} \quad (3)$$

其中, X 是心电信号的原始幅值, μ 是200个采样点幅值的平均值, δ 是200个采样点幅值的方差, X_{norm} 是归一化后的幅值。

1.3 基于级联分类器的心拍分类

本文采用级联分类器形式,分别采用SVM和W-MDC实现对PVC和LBBB的检出,分类器的总体框图见图1,特征向量1和特征向量2组成见表2。




图1 分类器的总体框图

Fig.1 Block diagram of Cascade classifier

ECG: Electrocardiogram; SVM: Support vector machine; NPVC: Non-premature ventricular contraction; W-MDC: Weighted minimum distance classifier

表2 特征向量及其组成
Tab.2 Composition of feature sets

Feature set	Feature group	Size
Feature set 1	R_Amp, Pre_RR, Cur_RR, Next_RR, QRS_Width, ST_Divation	6
Feature set 2	QRS_Width, QRS_Area, Cur_RR, Norm_Signal (Lead A + Lead B)	403

1.3.1 SVM用于PVC检出 SVM是一种常用的二值分类器,具有很强的分类性能和泛化能力,同时还具有速度快的优点,在模式识别中得到了广泛的应用。通过引入核函数,能够有效将数据映射到更高维度的平面,

使线性不可分的数据集变得线性可分。本文采用SVM首先将样本分为两类:PVC和非PVC(NPVC)。将R_Amp、Pre_RR、Cur_RR、Next_RR、QRS_Width、ST_divation组成的六维特征向量1输入到SVM中,选取适当的核函数、核函数中的参数以及惩罚因子C,实现对SVM分类效果的控制和优化。

1.3.2 W-MDC用于LBBB检出 最小距离分类器通过计算和比较未知样本到各类中心的距离,得到和未知样本距离最近的类心,则将该未知样本和该类心标记为同一类。传统的最小距离分类器中对于样本中的不同特征分量进行同等对待,考虑到不同特征包含的信息量不同以及对分类效果的影响存在着较大的差异,本文提出一种W-MDC,充分发挥不同特征在分类中的作用。该W-MDC的算法如下:

(1)筛选出训练集中被SVM标记为NPVC的心拍,提取NPVC的特征Cur_RR、QRS_Width及Norm_Signal,得到特征向量2 $X_{K \times N}$,其中 K 表示样本数量, N 表示特征量个数。

(2)设特征权值向量 $W = [w_1, w_2, \dots, w_N]$ 。对不同特征赋相应的权值,得到加权后的特征向量集:

$$X_{K \times N} = X_{K \times N} * W \quad (4)$$

(3)将特征向量集 $X_{K \times N}$ 分为LBBB数据集和正常心拍数据集,分别计算两数据集各特征的算术平均值得到各类数据集的中心:

$$U_i = [u_{i1}, u_{i2}, \dots, u_{iN}], \quad i = 1, 2 \quad (5)$$

其中, i 表示数据集类别,1代表正常心拍,2代表LBBB。

(4)对测试集中被SVM分类器标记为NPVC的心拍,提取相应特征得到特征向量 Y_N ,对不同特征赋相应的权值,得到加权后的特征向量集:

$$Y_N = Y_N * W \quad (6)$$

(5)计算该特征向量 $Y_N = [y_1, y_2, \dots, y_N]$ 到中心 U_i 的距离 d_i 。本文比较了基于Manhattan距离和基于Euclidean距离的分类效果, Euclidean距离和Manhattan距离的计算分别为式(7)和式(8):

$$d_i = \sum_{k=1}^N |y_k - u_{ik}|^2 \quad (7)$$

$$d_i = \sum_{k=1}^N |y_k - u_{ik}| \quad (8)$$

(6)计算该特征向量 Y_N 与中心 U_2 的相关系数 ρ :

$$\rho = \frac{Cov(Y_N, U_2)}{\sqrt{D(Y_N)} \sqrt{D(U_2)}} \quad (9)$$

其中,函数 $Cov(\cdot)$ 表示协方差, $D(\cdot)$ 表示方差,用来衡量特征向量 Y_N 与训练集中LBBB的相关性, ρ 越大,未知样本与训练集中LBBB相关性越强。

(7)根据式(10)中的条件判据对未知心拍进行标记:

$$\text{label} = \begin{cases} 2, & \text{if } \rho > 0.9 \ \& \ d_1 > d_2 \\ 1, & \text{else} \end{cases} \quad (10)$$

2 结果

将MIT-BIH心律失常数据库中的数据按表1分为训练集和测试集,用来验证本文提出的心律失常自动检测算法。分类效果采用准确度 Acc、灵敏度 Se 以及特异性 Sp 进行描述和评价,参数的定义如下:

$$\text{Acc} = \frac{\text{TP}}{\text{TP} + \text{FP} + \text{FN}} \quad (11)$$

$$\text{Se} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (12)$$

$$\text{Sp} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (13)$$

其中,TP表示正确分类的心拍数,FN表示实际为该类的的心拍被标记为其他类的心拍数,FP表示实际为其他类的心拍标记为该类型的心拍数。

2.1 基于级联分类器的心律失常识别结果

通过选用不同的核函数,得到当使用RBF核函数时最佳的分类效果。对惩罚因子C和RBF核方差σ两个参数进行联调,当C=20 000、σ=0.073时获得最佳分类结果,此时测试集DS2上PVC分类的混淆矩阵见表3。SVM分类器在测试集上的总体准确率 Acc 为98.35%。

表3 基于SVM的PVC分类混淆矩阵
Tab.3 Confusion Matrix of PVC detection based on SVM

Reference label	Algorithm label	
	NPVC	PVC
NPVC	46 098	330
PVC	487	2 731

将被SVM标记为NPVC的样本输入到最小距离分类器中进行训练和测试,进一步区分LBBB和N。考虑到临床上QRS波宽是LBBB诊断的重要指标,同时QRS波宽数值相对较小,因此要增大QRS波宽的特征权重。取两通道的Norm_Signal特征,得到403维特征向量,令QRS_Width权重为200, QRS_Area权重为0.5,其他特征权重为1,采用Manhattan距离并结合式(10)的判据,得到表4所示的测试集DS2上N、LBBB和PVC三分类的混淆矩阵。级联分类器三分类的准确率、灵敏度和特异性见表5。在整个测试集DS2上,总体分类正确率为96.28%。对正常心拍,分类的Acc、Se、Sp分别为98.81%、98.58%、97.16%;对于LBBB,分类的Acc、

Se、Sp分别为75.95%、81.41%、91.89%;对于PVC,分类的Acc、Se、Sp分别为76.90%、89.05%、84.93%。

表4 基于级联分类器的三分类的混淆矩阵
Tab.4 Confusion Matrix based on Cascade classifier

Reference label	Algorithm label		
	N	LBBB	PVC
N	41 712	268	328
LBBB	764	3 354	2
PVC	459	28	2 731

表5 基于级联分类器的三分类性能指标(%)
Tab.5 Performance evaluation of Cascade classifier (%)

Reference label	Accuracy	Sensitivity	Specificity
N	95.82	98.59	97.15
LBBB	75.95	81.41	91.89
PVC	76.97	89.22	84.87

2.2 最小距离分类器判据对于LBBB分类的影响

本文比较了基于Euclidean距离和基于Manhattan距离的最小距离分类器的分类效果,同时也比较了相关系数引入对于分类结果的影响。从表6结果来看,基于Manhattan距离的最小距离分类器对于LBBB分类具有最佳的灵敏度,达到98.16%。结合Manhattan距离与相关系数,显著提高了分类的准确率和特异性,取得了最佳的整体分类效果。

2.3 W-MDC和经典最小距离分类器(MDC)性能比较

本文基于Manhattan距离对比了MDC和W-MDC对于LBBB的分类效果。由表7可知,相比于MDC, W-MDC显著提升了对于LBBB的分类性能,尤其是特异性,这也间接证明了QRS波宽在LBBB识别中的重要性。

2.4 导联对于LBBB分类的影响

本文通过分别选取通道A、通道B以及联合通道A通道B的Norm_Signal特征,比较了不同导联以及导联数对于LBBB分类的影响。由表8可得,基于通道A的LBBB检测具有更高的特异性,基于通道B的LBBB检测具有更高的灵敏度和准确度。通过综合多个导联信息,用于LBBB的联合诊断,总体准确度、灵敏度和特异性都得到了显著提升。

2.5 结果比较

目前,虽然已有大量有关心拍分类的工作,但考虑

表6 不同判据下级联分类器的分类结果

Tab.6 Classification results of Cascade classifier under different criteria

Reference label		N	LBBB	PVC
Euclidean distance	N	39 311	2 664	328
	LBBB	383	3 735	2
	PVC	323	164	2 731
Manhattan distance	N	38 724	3 256	328
	LBBB	74	4 044	2
	PVC	346	143	2 731
Euclidean distance+ correlation coefficient ρ	N	41 489	491	328
	LBBB	736	3 383	2
	PVC	460	27	2 731
Manhattan distance+ correlation coefficient ρ	N	41 712	268	328
	LBBB	764	3 354	2
	PVC	459	28	2 731

表7 加权最小距离分类器(W-MDC)和经典最小距离分类器(MDC)分类结果对比

Tab.7 Performance comparison between W-MDC and MDC

Reference label		N	LBBB	PVC
MDC	N	36 907	5 062	328
	LBBB	231	3 887	2
	PVC	345	142	2 731
W-MDC	N	38 724	3 259	328
	LBBB	74	4 044	2
	PVC	346	143	2 731

表8 不同导联下的分类结果

Tab.8 Classification results of Cascade classifier under different lead configurations

Reference label		N	LBBB	PVC
Lead A	N	41 764	216	328
	LBBB	3 856	262	2
	PVC	429	251	2 731
Lead B	N	31 333	10 647	328
	LBBB	226	3 892	2
	PVC	378	109	2 731
Lead A+B	N	41 712	268	328
	LBBB	764	3 354	2
	PVC	459	28	2 731

到病人间差异划分训练集和测试集,用于PVC和LBBB分类验证的研究非常有限。表9列出了现有的考虑到病人间差异性,进行病人内心拍分类研究的结果。实际上,由于数据集的差异以及分类种类的不同,很难对这些算法进行公平的比较。文献[10]仅给出了分类的灵敏度,没有给出特异性及准确性,不能完整反映该算法的实际分类性能。表6中基于Manhattan距离分类,LBBB的Se达到98.16%,高于文献[10]。文献[15]的方法取得了非常好的实验结果,但该方法在训练集和测试集中每种类型的心拍仅各150个,样本数量少,大大降低了分类难度,泛化能力有待进一步验证。表10比较了文献[12]和本文对于LBBB的分类效果,其中,文献[12]中N仅包含正常心拍,而本文中的N为除LBBB和PVC外的所有心拍。总体来看,本文提出的算法相比文献[12]在LBBB自动检测上具有显著优势。

表9 分类性能比较(%)

Tab.9 Classification performance comparison (%)

Method	N		LBBB		PVC	
	Sensitivity	Specificity	Sensitivity	Specificity	Sensitivity	Specificity
Mishra ^[10]	93.15	-	82.37	-	91.07	-
Dokur ^[15]	100.00	96.70	94.60	91.00	91.30	93.50
Huang ^[12]	81.50	98.00	91.40	37.30	-	-
Our work	98.59	97.15	81.41	91.89	89.22	84.87

3 结 论

本文提出一种级联分类器用于心律失常的自动检测,通过提取时域和形态特征,基于SVM实现

PVC和非PVC的分类,再采用W-MDC进一步将非PVC分为N和LBBB。考虑到病人间的差异性远大于病人内的差异性,本文在训练集和测试集上选用来自不同个体的心电样本,测试该算法在病人间心

表10 LBBB分类结果比较

Tab.10 LBBB detection results

Method		N	LBBB
Huang ^[12]	N	29 979	6 465
	LBBB	355	3 770
Our work	N	41 712	268
	LBBB	764	3 354

拍分类的性能和泛化能力。同时,该算法还分析了不同特征及导联对于分类效果的影响。未来,还可以通过综合更多导联的信息,以及引入新的特征提取手段和自动识别技术,进一步提升各种心律失常心拍的分类准确率,实现对更多种类异常心拍的自动识别。

【参考文献】

- [1] World Health Organization. Global status report on noncommunicable diseases 2014[R]. Geneva: World Health Organization, 2015.
- [2] 陈新. 黄宛临床心电图学[M]. 第6版. 北京: 人民卫生出版社, 2009: 275-281.
CHEN X. Huang Wan clinical electrocardiogram[M]. 6th ed. Beijing: People's Medical Publishing House, 2009: 275-281.
- [3] CORTIGIANI L, RIGO F, GHERARDI S, et al. Prognostic implication of Doppler echocardiographic derived coronary flow reserve in patients with left bundle branch block[J]. Eur Heart J, 2013, 34(5): 364-373.
- [4] BARSHESHET A, MOSS A J, MCNITT S, et al. Long-term implications of cumulative right ventricular pacing among patients with an implantable cardioverter-defibrillator[J]. Heart Rhythm, 2011, 8(2): 212-218.
- [5] TOMPKINS C, KUTYIFA V, MCNITT S, et al. Effect on cardiac function of cardiac resynchronization therapy in patients with right bundle branch block (from the multicenter automatic defibrillator implantation trial with cardiac resynchronization therapy [MADIT-CRT] trial)[J]. Am J Cardiol, 2013, 112(4): 525-529.
- [6] YE C, KUMAR B V, COIMBRA M T. Heartbeat classification using morphological and dynamic features of ECG signals[J]. IEEE Trans Biomed Eng, 2012, 59(10): 2930.
- [7] CHRISTOV I, GOMEZ-HERRERO G, KRASTEVA V, et al. Comparative study of morphological and time-frequency ECG descriptors for heartbeat classification[J]. Med Eng Phys, 2006, 28(9): 876-887.
- [8] JEKOVA I, BORTOLAN G, CHRISTOV I. Assessment and comparison of different methods for heartbeat classification [J]. Med Eng Phys, 2008, 30(2): 248-257.
- [9] MAJI U, MITRA M, PAL S. Imposed target based modification of Taguchi method for feature optimisation with application in arrhythmia beat detection[J]. Expert Syst Appl, 2016, 56(C): 268-281.
- [10] MISHRA A K, RAGHAV S. Local fractal dimension based ECG arrhythmia classification[J]. Biomed Signal Proces, 2010, 5(2): 114-123.
- [11] DE CHAZAL P, DWYER M O, REILLY R B. Automatic classification of heartbeats using ECG morphology and heartbeat interval features [J]. IEEE Trans Biomed Eng, 2004, 51(7): 1196-1206.
- [12] HUANG H, LIU J, ZHU Q, et al. Detection of inter-patient left and right bundle branch block heartbeats in ECG using ensemble classifiers [J]. Biomed Eng Online, 2014, 13(1): 72.
- [13] LIN C H, DU Y C, CHEN T. Adaptive wavelet network for multiple cardiac arrhythmias recognition[J]. Expert Syst Appl, 2008, 34(4): 2601-2611.
- [14] KUTLU Y, KUNTALP D. Feature extraction for ECG heartbeats using higher order statistics of WPD coefficients [J]. Comput Methods Programs Biomed, 2012, 105(3): 257-267.
- [15] DOKUR Z, OLMEZ T. ECG beat classification by a novel hybrid neural network[J]. Comput Meth Prog Bio, 2001, 66(2-3): 167.
- [16] OSOWSKI S, LINH T H. ECG beat recognition using fuzzy hybrid neural network[J]. IEEE Trans Biomed Eng, 2001, 48(11): 1265.
- [17] OSOWSKI S, HOAI L T, MARKIEWICZ T. Support vector machine-based expert system for reliable heartbeat recognition[J]. IEEE Trans Biomed Eng, 2004, 51(4): 582.
- [18] KIM J, HANG S S, SHIN K, et al. Robust algorithm for arrhythmia classification in ECG using extreme learning machine[J]. Biomed Eng Online, 2009, 8(1): 31.
- [19] YU S N, CHOU K T. Integration of independent component analysis and neural networks for ECG beat classification[J]. Expert Syst Appl, 2008, 34(4): 2841-2846.
- [20] 金林鹏, 董军. 面向临床心电图分析的深度学习算法研究[J]. 中国科学: 信息科学, 2015, 45(3): 398-416.
JIN L P, DONG J. Deep learning research on clinical electrocardiogram analysis [J]. Chinese Science: Information Science, 2015, 45(3): 398-416.
- [21] LUZ E J, SCHWARTZ W R, CÁMARA-CHÁVEZ G, et al. ECG-based heartbeat classification for arrhythmia detection: a survey[J]. Comput Methods Programs Biomed, 2016, 127(C): 144.
- [22] 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.
- [23] Testing and reporting performance results of cardiac rhythm and ST segment measurement algorithms[S]. American National Standard ANSI/AAMI EC57: 1998.
- [24] SALIH S K, ALJUNID S A, ALJUNID S M, et al. High speed approach for detecting QRS complex characteristics in single lead electrocardiogram signal [C]//IEEE International Conference on Control System, Computing and Engineering. IEEE, 2014: 391-396.

(编辑:陈丽霞)