

基于集成学习的室性早搏识别方法

周飞燕^{1,2}, 金林鹏^{1,2}, 董 军¹

(1. 中国科学院苏州纳米技术与纳米仿生研究所, 江苏苏州 215123; 2. 中国科学院大学, 北京 100049)

摘 要: 本文提出了一种集成学习方法以提升室性早搏的识别性能. MIT-BIH 两个通道的数据分别经过卷积神经网络进行室性早搏心拍分类, 然后按照融合规则对分类结果进行融合决策, 其准确率、灵敏度和特异性分别为 99.91%、98.76%、99.97%, 优于已有算法的室性早搏心拍分类结果. 此外, 面向临床应用, 本文还利用卷积神经网络和诊断规则相结合的方法实现了病人间室性早搏识别实验, 在有 14 万多条记录的数据集上, 取得的准确率、灵敏度及特异性分别为 97.87%、87.94%、98.02%, 验证了该算法的有效性.

关键词: 室性早搏; 卷积神经网络; 诊断规则

中图分类号: TP391

文献标识码: A

文章编号: 0372-2112 (2017)02-0501-07

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2017.02.032

PVC Recognition Algorithm Based on Ensemble Learning

ZHOU Fei-yan^{1,2}, JIN Lin-peng^{1,2}, DONG Jun¹

(1. Suzhou Institute of Nano-tech and Nano-bionics, Chinese Academy of Sciences, Suzhou, Jiangsu 215123, China;

2. University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: In order to improve the recognition performance of premature ventricular contraction (PVC), this paper reports an algorithm based on ensemble learning. First, the tow-lead ECG signals from the MIT-BIH Arrhythmia database are classified into PVC and non PVC beats using lead convolutional neural network (LCNN) classifier. Then the results are fused with some rules. The accuracy, sensitivity and specificity of the proposed algorithm are 99.91%, 98.76% and 99.97%, respectively, which are better than that of other existing algorithms for PVC beats classification. In addition, this paper realizes an inter-patient PVC recognition experiment by combining LCNN and diagnostic rules for clinical application. The effectiveness of the proposed algorithm has been confirmed by the accuracy (97.87%), sensitivity (87.94%) and specificity (98.02%) with the data set over 140000 ECG records.

Key words: premature ventricular contraction (PVC); lead convolutional neural network (LCNN); diagnosis rules

1 引言

一条心电图 (Electrocardiogram, ECG) 记录由多个心拍 (heartbeat, 即心动周期) 组成, 每一个心拍一般又由 P 波、QRS 波群、T 波及 U 波组成. 图 1 为 ECG 中一个典型心拍的结构示意图. 人们根据这些波形定义了 PR 间期、QT 间期、RR 间期、ST 段、QRS 宽度等相关特征参数, 这些特征参数具有重要的临床诊断意义.

根据 ECG 的波形尤其是 QRS 波形来诊断室性早搏 (Premature Ventricular Contraction, PVC) 是临床诊断 PVC 的一种行之有效的方法. PVC 是提早发生的起源于心室的异常心跳, 也是临床常见的心律失常之一. 因此, 正确检测、自动识别 PVC 具有非常重要的临床意

义. 目前, 心拍分类的方法已有很多, 如支持向量机^[1,2]、神经网络^[3,4]、模糊数学^[5]、疾病规则^[6]等. 多数 PVC 检测算法在标准心电图数据库上均能得到较好的分类性能, 准确率也较高^[7]. 然而许多相关的研究工作仅利用标准心电图数据库中的部分类型或者部分数据, 这不利于不同模型比较, 也不能充分体现算法的分类性能. 2012 年, Can Ye 等^[8]采用小波变换、ICA 及 PCA 方法提取特征, 同时还加入 4 个 RR 间期, 然后经过 SVM 分类, 最后采用贝叶斯方法对两个导联的分类结果进行融合决策, 得到了该方法在 MIT-BIH 中 48 条记录上 16 类 (包括 PVC 类) 心拍分类的结果. 其总的准确率为 99.32%, 该准确率为目前公开发表文献中在 MIT-BIH 上取得的最高心拍分类准确率. 按照 AAMI

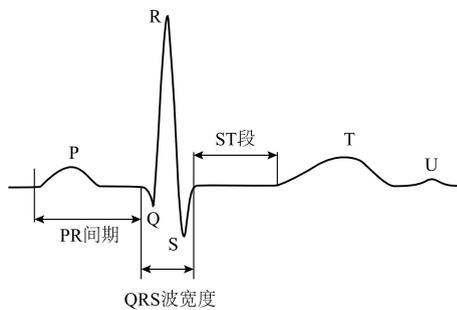


图1 心拍结构示意图

标准^[9]将文献[8]的16类分类结果折合成PVC类和非PVC类,该算法得到的灵敏度、特异性及准确率分别为98.27%、99.85%和99.77%。上述方法中,传统神经网络算法运算量大、训练时间较长,难以实现实时检测。而模糊数学方法需要简化很多临床判别规则,难以适应复杂的ECG记录。本文提出一种基于集成学习的PVC识别方法,鉴于导联卷积神经网络(Lead Convolutional Neural Network, LCNN)^[10]训练参数少、自适应强等优良特性,将LCNN作为集成学习的基分类器。理论和实验表明本文提出的方法具有良好的PVC分类性能及应用价值。

2 基于集成学习的PVC识别方法

本文所提出的PVC识别流程如图2所示,先采用 n 个LCNN进行并行分类,然后从这 n 个分类器中选取 y 个分类器进行融合决策,再融入PVC诊断规则进行串行分类。首先,由 n 个分类器对经过预处理后的ECG进行PVC分类。经每个LCNN分类后,得到 n 个分类器的 n 个分类结果。事实上每个分类器的分类结果实际上输出的是概率值,可根据这个概率值来判断该ECG是否为PVC。但是为了提升分类结果的可靠性,这里首先在 n 个分类器中选取 y 个分类器的结果并按照合适的融合规则对这 y 个分类器的结果进行融合决策,得到由 y 个LCNN分类后的最终结果。由于经 y 个LCNN分类后,得到的灵敏度还是比较低,为了提升整体分类性能,我们采用PVC的ECG诊断规则(图2中的虚线部分)对LCNN判断出来的非PVC(记NPVC)作再次判断。

目前,鲜有人将LCNN应用于集成学习中,并且关于识别PVC的研究工作大都是基于统计学习的方法或者是基于其诊断规则的方法。本文充分利用LCNN及疾病诊断规则各自的内在优势,首先基于LCNN进行选择集成,然后再融入PVC诊断规则,取得了良好的分类结果。

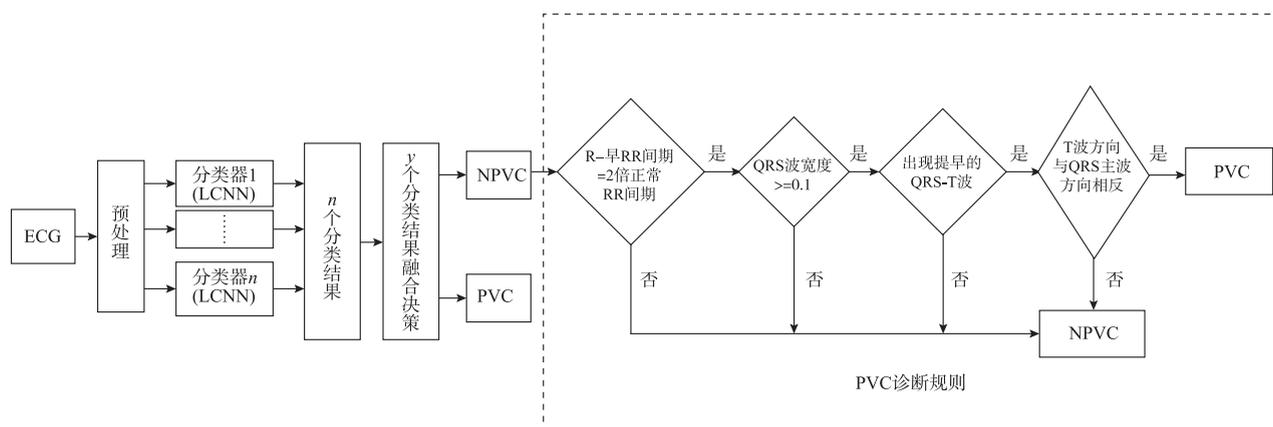


图2 PVC判别流程图

2.1 预处理

在临床中,ECG常受到各种噪声的干扰,如基线漂移、工频干扰及肌电干扰等。为了抑制噪声,提升ECG的信噪比,以利于进行ECG自动分析,需对ECG作噪声滤波处理。目前,所采用的ECG去噪方法有低通滤波^[11]、小波变换^[12]及Hilbert-Huang变换^[13]等。鉴于带通滤波具有简单、快速等优点,本文采用0.5~40Hz的带通滤波去除噪声干扰,通过该带通滤波可将ECG噪声基本滤除,从而有利于后续的分类过程。

2.2 集成学习

本文方法实际上是一种选择性集成方法,即从已训练好的一组分类器(n 个分类器)中选择部分分类器

(y 个分类器)进行集成,这 y 个分类器对于特定的数据均具有较好的分类结果,各分类器间存在较大差异性。并且每个分类器的错误率都应低于0.5,否则反而会提升集成结果的错误率^[14]。文献[15]为选择性集成提供了理论依据,说明了选择性集成的有效性。本文主要采用LCNN作为基分类器,同时还引入诊断规则以提升整个分类性能,采用的融合算法有加法融合和乘积融合^[16]。下面给出它们的计算公式。

将 y 个LCNN记为 $N = (N_1, N_2, \dots, N_y)$,两类类别记为 $T = (T_1, T_2)$ 。其中 $T_1 = 0$ 表示NPVC类, $T_1 = 1$ 为PVC类。则 y 个LCNN对于待测试样本 x 的输出可用式(1)的矩阵表示:

$$\begin{bmatrix} t_{11} & t_{12} \\ \vdots & \vdots \\ t_{i1} & t_{i2} \\ \vdots & \vdots \\ t_{y1} & t_{y2} \end{bmatrix} \quad (1)$$

其中, t_{ij} 表示 x 被分类器 i 判别为第 j ($j=1$ 表示类别为 T_1 类, $j=2$ 表示类别为 T_2 类) 类的概率值。

2.2.1 加法融合

$$P_j = \sum_{i=1}^y t_{ij} \quad (2)$$

2.2.2 乘积融合

$$P_j = \prod_{i=1}^y t_{ij} \quad (3)$$

经上述方法对 y 个分类器的输出进行融合, 得到向量 $[P_1, P_2]$, 然后通过下式来确定样本所属的最终类别:

$$\text{assign } x \rightarrow T_k, \text{ if } P_k = \max(P_1, P_2), k = 1, 2 \quad (4)$$

2.3 LCNN

多导联 ECG 的数据组织形式是一个矩阵, 可直接采用二维结构的卷积神经网络进行训练和分类. 这种二维结构的卷积神经网络一般对行方向和列方向均进行卷积计算, 然而这对多导联 ECG 并不合适, 因为多导联 ECG 导联内数据是相关的, 而导联间数据是独立的. 据此, 金林鹏等^[10] 提出导联卷积神经网络 (LCNN) 模型, 并将该模型应用于 CCDD 数据库上的正异常分类,

取得了较高的准确率. LCNN 去掉了不同导联间的卷积计算, 具有天然的并行计算特性, 非常有利于缩短训练时间^[10]. 此外, LCNN 通过权值共享减少训练参数, 降低了网络复杂度和训练难度, 也避免了传统 BP 网络中由于参数过多引起过拟合及容易陷入局部最小值的缺欠.

2.4 诊断规则

PVC 在心电图上所表现出的一些基本特征为: ① QRS 波畸形, 其宽度大于等于 0.10s; ② R-早 R-R 间期是正常的 R-R 间期的 2 倍, 即代偿间期完全; ③ 出现提早的 QRS-T 波; ④ T 波方向与 QRS 主波方向相反. 因此我们选择 R-R 间期、QRS 波宽度、T 波方向、QRS 主波方向作为特征参数. 如果 ECG 满足上述基本特征, 则该 ECG 就有可能为 PVC.

PVC 的 ECG 图形如图 3 所示. 从图 3 中可看出 PVC 出现时, PVC 心拍 R 峰离其前一个心拍的 R 峰较近, 而离其后一个心拍的 R 峰较远, 同时 QRS 波宽大畸形, T 波方向也与 QRS 主波方向相反. 本文利用心电图特征点定位算法^[17] 确定 R 波的位置、QRS 波起止点及 T 波位置, 并将 ECG 记录分成一系列的心动周期. 由这些特征点位置提取以上特征参数. 图 2 中的虚线部分为 PVC 诊断规则的判别流程, 即由 LCNN 进行集成后判断出来的 NPVC 数据需采用其诊断规则作再次的判断.

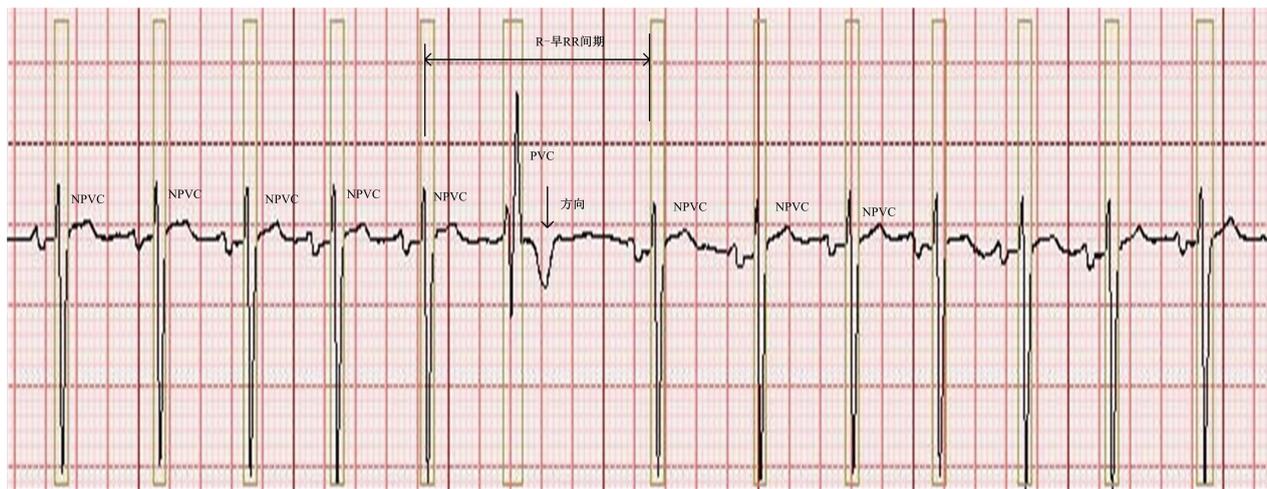


图3 CCDD数据库中的一条PVC记录

3 实验与结果分析

3.1 ECG 实验数据集

3.1.1 MIT-BIH 数据库

MIT-BIH 数据库^[18] 包含 48 条心电图记录, 是国内外研究者常用的标准心电图数据库之一. 数据库中每

条记录长 30 分钟, 采样率为 360Hz; 每条记录包含两个导联的数据, 根据导联所在位置可将这两个导联记为 A 通道和 B 通道. 则 A 通道中除 102、104、114 记录为 v5 导联外, 其他记录为 II 导联; B 通道中有 1 条记录为 II 导联、1 条为 v4 导联、2 条为 v5 导联、4 条为 v2 导联、其余 40 条为 v1 导联. 每条记录标注了 QRS 主波位置以

及心拍对应的疾病类型.

3.1.2 中国心血管疾病数据库

中国心血管疾病数据库^[19] (Chinese Cardiovascular Disease Database, CCDD, <http://58.210.56.164:88/ccdd/>)是为了研究面向临床的心电图分析算法而构建的,其中的数据均来自临床,目前包含近 18 万条 12 导联 500Hz 采样率心电图记录,均有整条记录的诊断结论.

3.2 评价指标

在计算机辅助心电图分析算法研究中,经常使用准确率 (Acc)、灵敏度 (Se)、特异性 (Sp)、正检测率 (+P) 及负检测率 (-P) 等作为算法性能的评价指标. 基于表 1 的混淆矩阵,它们的定义如下^[10]:

表 1 PVC 分类的混淆矩阵

真实类别	预测类别	
	NPVC(0)	PVC(1)
NPVC(0)	TN	FP
PVC(1)	FN	TP

$$Acc = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (5)$$

$$Se = \frac{TP}{(TP + FN)} \quad (6)$$

$$Sp = \frac{TN}{(TN + FP)} \quad (7)$$

$$+P = \frac{TP}{(TP + FP)} \quad (8)$$

$$-P = \frac{TN}{(TN + FN)} \quad (9)$$

3.3 MIT-BIH 数据库上的 PVC 识别

为了与已发表的文献作对比,我们也以 MIT-BIH 数据库为基础做了基于病人内的 PVC 心拍分类. 我们按照文献[8]的数据处理方法,取 R 波前 199 个采样点、R 波后 200 个采样点,包括 R 波共 300 个采样点作为一个心拍数据. 最终,48 条记录每个导联分别共截取了 110109 个心拍. 首先将这些心拍数据归一化到 $[-1, 1]$, 然后分别取 24100 个心拍进行训练 (和对照文献[8]一致), 其余心拍为测试数据. 由于 MIT-BIH 中每条记录的导联不完全一致, 因此在 MIT-BIH 数据库上识别 PVC 的方法与第 2 部分识别 PVC 的方法略有不同. MIT-BIH 上识别 PVC 的流程图如图 4 所示.

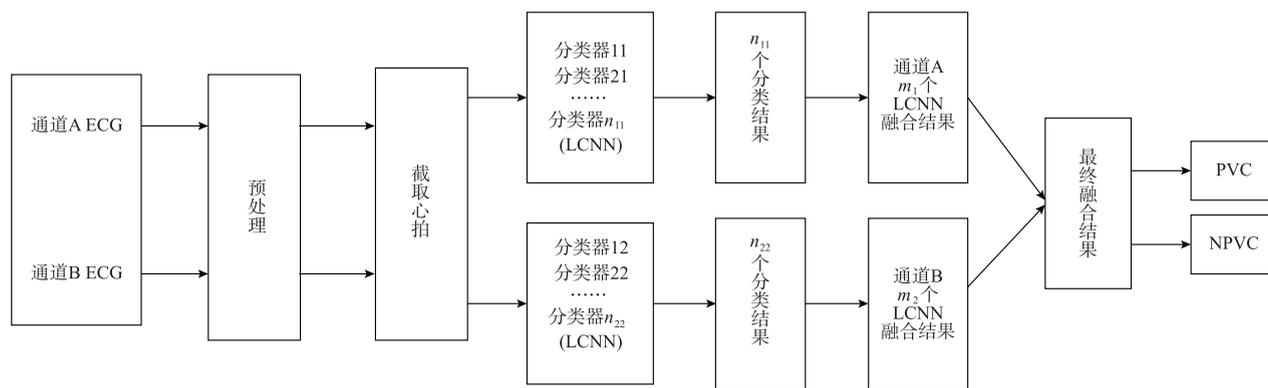


图4 PVC心拍识别流程图

每个心拍分别来自 A、B 两个通道,这两个心拍信号可视为对来自两个不同位置的相同心脏活动的两个观察^[8],即从理论上来说对于不同的导联在同一时刻的心拍对应的疾病类型相同. 因此,可将这两个心拍信号的分类结果进行融合决策来提升分类的可信度. 在本文中,将来自 A 通道的 24100 个心拍分别均经过 n_{11} 个 LCNN 进行独立训练,然后将 A 通道的其余心拍均作为这些分类器的测试样本. 同样的,将来自 B 通道的 24100 个心拍(这些心拍与 A 通道的 24100 个心拍是相同记录相同时刻不同导联的心拍)分别经过 n_{22} 个 LCNN 进行独立训练,再将 B 通道的其余心拍作为它们的测试样本. 最终, A 通道得到 n_{11} 个分类结果, B 通道得到 n_{22} 个分类结果. 从 A 通道的 n_{11} 个分类结果中选择 m_1 个分类结果,采用加法融合规则和乘法融合规则将

m_1 个分类结果进行融合决策. 做法为: 首先将 m_1 个分类结果按照两两结合的方式进行融合决策来确定 m_1 个分类结果之间的差异性程度, 最终发现第 h 个分类结果与其它 $m_1 - 1$ 个分类结果的差异性更大. 这里, 我们先采用乘法融合规则将 $m_1 - 1$ 个分类结果进行融合, 然后再将该融合结果与第 h 个分类结果按加法融合规则进行融合得到 A 通道中 m_1 个分类结果的最终融合结果 P_j^A ($j=1, 2, 1$ 表示 T_1 类, 2 表示 T_2 类). 类似地, B 通道的 n_{22} 个结果中选取 m_2 个分类结果按照乘法融合规则对 m_2 个结果进行融合决策得到融合结果 P_j^B ($j=1, 2$). 最后, 采用加法规则将 A 通道的融合结果和 B 通道的融合结果进行融合得到最终的融合结果. 本文在对 A、B 通道进行融合前首先对它们的融合结果进行归一化, 则最终融合结果为:

$$P_j = \frac{P_j^A + P_j^B}{\sum_{g=1}^2 (P_g^A + P_g^B)}, j=1,2 \quad (10)$$

测试样本 x 最终的类别由式(4)确定.

本文中, n_{11}, n_{22} 取值均为 15, 实际上, 还可以训练更多的 LCNN 模型. m_1 取值为 7, m_2 为 8, 其中 m_1 和 m_2 的取值取决于各基分类器之间的差异性程度及其分类的效果, 是分别从已训练好的 LCNN 中选出来的结果较好、彼此间差异性较大的分类器. 这些 LCNN 的 3 个取样步的大小均为 $1 * 3$, 3 个卷积核的大小分别为 $1 * 13$, $1 * 10$ 和 $1 * 6$. 区别在于它们的特征面个数和训练方法不同. LCNN 的特征面个数和卷积核大小由经验而定. A 通道中 7 个 LCNN 的结构为 $[10, 15, 25, 50, 2]$, 其中 10、15 和 25 分别表示 3 个卷积单元的特征面个数, 50 和 2 分别表示两个全连接层的神经元个数. 由于 PVC 类和非 PVC 类数据不平衡, 我们采用加权的方式来处理此问题, 即在 LCNN 的损失函数中对每一个类别设置不同的错分代价, 同时这样做也可以使训练所得的多个基分类器有所差异, 从而使集成学习更加有效. 7 个 LCNN 中有 1 个的错分代价比为 1:6 即非 PVC 与 PVC 的错分代价之比为 1:6, 1 个为 1:7, 3 个为 5:1; 但是训练初始值不一样, 2 个为 4:1. B 通道的 8 个 LCNN 结构均为 $[20, 30, 40, 50, 2]$, 卷积核以及全连接层神经元个数与 A 通道的相同. 这 8 个 LCNN 中有 1 个的错分代价之比为 3:1; 2:1 和 5:1 分别为 2 个; 3 个为 7:3. 经过以上分类后, 在 MIT-BIH 上识别 PVC 得到的结果如表 2 所示.

表 2 MIT-BIH 中 PVC 心拍识别结果

模型	分类结果		Sp/%	Se/%	-P/%	+P/%	Acc/%
	NPVC	PVC					
	0	1					
文献[8]	0	81611 121	99.85	98.27	99.91	97.20	99.77
	1	74 4203					
本文	0	81706 26	99.97	98.76	99.94	99.39	99.91
	1	53 4224					

从表 2 可看出, 本文算法得到的 PVC 分类结果优于对照文献, 各项指标值均大于对照文献的指标值. 实验结果表明本文采用 LCNN 作为基分类器, 并采用融合规则将各分类结果进行融合决策取得了更好的分类结果. 在本文中, 只取了心拍数据进行训练, 没有加入 R-R 间期特征, 且基于 LCNN 的优良特性, LCNN 在样本维数(本文为 300)及数据规模比较大的情况下, 其计算时间也具有一定的优势.

3.4 CCDD 数据库上的 PVC 识别

为了面向临床应用, 这里采用的数据为 CCDD 数

据库全部数据. LCNN 采用 CCDD 数据库中前 35840 条记录作为训练样本, 其余记录作为测试数据. 同样地, ECG 记录也需要先经过 0.5 ~ 40Hz 的带通滤波去除噪声, 然后下采样到 200Hz, 再截取 9.5s 的数据并将数据输入 20 个(对应图 2 的 n) LCNN 进行并行独立训练. 与 MIT-BIH 中的区别在于这里并未截取 ECG 的心拍而是对 ECG 记录均截取 9.5s 的原始数据作为实验数据, 且同一个病人的 ECG 数据不会同时出现在训练集和测试集里, 即其属于按记录的病人间 PVC 分类, 这是符合临床实际应用的. 从 20 个已训练好的 LCNN 模型中, 选取 6 个(对应图 2 的 γ) 分类结果较好且彼此间差异性较大的 LCNN 模型进行集成. 这里, 6 个 LCNN 的 3 个取样步大小均为 $1 * 3$, 3 个卷积核大小分别为 $1 * 18$, $1 * 10$ 和 $1 * 5$. 在 6 个 LCNN 中: 有 3 个的结构为 $[15, 20, 15, 50, 1]$, 这 3 个中有 2 个的错分代价比均为 3:1, 只是训练初始值不一样, 另外一个的错分代价比为 1:4; 另外 3 个中, 有 2 个的结构均为 $[8, 14, 20, 50, 2]$, 1 个为 $[10, 15, 20, 50, 2]$, 这 3 个的错分代价比均为 4:1. 将这 6 个 LCNN 的分类结果按照加法融合规则进行融合决策后, 得到的灵敏度为 64.25%, 特异性为 99.00%. 经 LCNN 进行集成分类后所得 PVC 识别的灵敏度还是比较低, 因此我们考虑采用 PVC 的诊断规则对 LCNN 预测出来的 NPVC 数据作再次判断以提高灵敏度, 整个 PVC 识别框图如图 2 所示. 由 LCNN 与 PVC 诊断规则相结合的方法(简称为融合方法)得到的结果如表 3 所示.

表 3 CCDD 中 PVC 识别对比结果

模型	分类结果		Sp/%	Se/%	-P/%	+P/%	Acc/%
	NPVC	PVC					
	0	1					
LCNN	0	125066 13822	90.04	79.61	99.65	11.00	89.88
	1	438 1710					
融合	0	136151 2747	98.02	87.94	99.81	40.75	97.87
	1	259 1889					

从表 3 可看出, 采用这种集成的方式识别 PVC 得到的各项指标优于只使用单个 LCNN 所得的结果, 整体分类性能有所提升. 相比于 MIT-BIH, CCDD 上得到的各性能指标均有所下降. 这是由于前者训练集和测试集来自同一个人不同时刻的心拍, 使得其分类能力显得过于乐观; 而对于病人间分类, 测试集中病人的信息不会出现在训练集中, 因此分类性能要下降.

为了减少医生的工作压力, 改善医疗服务质量, 许多研究者一直致力于研究 ECG 计算机辅助诊断系统^[20]. 文献[10]以文献[21]的研究工作为基础, 提出了更符合临床实际的 LCNN 分类模型, 将其移植到云计算平台上实现了心律不齐、房颤、房性早搏和室性早搏

等疾病的判断. 王丽苹^[22]等以有经验的医学专家诊断过程为基础,将诊断过程中的领域知识与医生视觉信息中形态模式相结合来建立统计分类模型,获得了良好的分类效果. 本文基于 LCNN 和 PVC 诊断规则互补的集成学习方法,取得了较好的分类结果. 从表 3 可知,使用单个 LCNN 模型识别 PVC 的准确率只有 89.88%,识别效果不是很好. 本文方法的识别准确率达到到了 97.87%,且其他各项指标均有所提升,说明融合算法确实能够提升 PVC 的整体识别性能.

Hakacova 等^[23]在 2012 年统计了市场上一些心电图机的自动诊断结果,总共统计了 576 例心电图. 根据其统计表,将统计结果折合成 PVC 和 NPVC 两类. 发现 Philips medical 自动诊断 PVC 的平均 Acc 为 96.53%, Se 为 84.85%, Sp 为 97.24%; Draeger medical systems 的平均 Acc 为 95.49%, Se 为 78.79%, Sp 为 96.50%; 同时该报告还给出了 3 名普通医生判读 PVC 心电图的平均 Acc 为 97.40%, Se 为 72.73%, Sp 为 98.90%. 本文的 PVC 分类模型在 14 多万条记录上取得了 97.87% 的 Acc、87.94% 的 Se 和 98.02% 的 Sp,具有良好的临床应用和参考价值.

4 小结

本文利用各个分类器之间存在较大的差异性以及 LCNN 和诊断规则各自的特点来改善疾病分类模型的泛化能力,实验结果表明了本文算法的有效性,对医生的疾病诊断可以起到积极的辅助作用. 为了能够更好地提升整体分类性能,我们进一步研究的问题是如何选择部分分类器且有效地使之集成. 同时,为了提高心电图各个特征点的识别准确率以及疾病分类的准确率,我们还需学习新的理论及技术.

参考文献

- [1] KHAZAEI Ali. Combining SVM and PSO for PVC detection [J]. *International Journal of Advances in Engineering Sciences*, 2013, 3(4): 1-5.
- [2] HUANG Dong, LIAO Zhengquan, LI Changbin, et al. ECG PVC classification algorithm based on fusion SVM and wavelet transform [J]. *International Journal of Signal Processing, Image Processing and Pattern Recognition*, 2015, 8(1): 193-201.
- [3] INAN O T, GIOVANGRANDI L, KOVACS G T A. Robust neural-network-based classification of premature ventricular contractions using wavelet transform and timing interval features [J]. *IEEE Transactions on Biomedical Engineering*, 2006, 53(12): 2507-2515.
- [4] MITTAL Ankita, AHLAWAT Meena. Detection of cardiac arrhythmias using different neural networks; a review [J]. *International Journal of Advanced Research in Computer and Communication Engineering*, 2014, 3(6): 6992-6995.
- [5] 孟兆辉,张永红,白净. 模糊算法在心律失常病类判别中的应用[J]. *电子学报*, 2001, 29(9): 1246-1248. MENG Zhaohui, ZHANG Yonghong, BAI Jing. A fuzzy method for classification of arrhythmias [J]. *Acta Electronica Sinica*, 2001, 29(9): 1246-1248. (in Chinese)
- [6] LEK-UTHAI Apiwat, ITTATIRUT Supat, TEERAMON-GKONRASMEE Arporn. Algorithm development for real-time detection of premature ventricular contraction [A]. *TENCON 2014-2014 IEEE Region 10 Conference [C]*. Bangkok: IEEE, 2014: 1-5.
- [7] KANWAR Geeta, DEWANGAN Naveen Kumar, DEWANGAN Kiran. A review: detection of premature ventricular contraction beat of ECG [J]. *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, 2015, 4(2): 939-942.
- [8] YE Can, KUMAR B V K Vijaya, COIMBRA Miguel Tavares. Heartbeat classification using morphological and dynamic features of ECG signals [J]. *IEEE Transactions on Biomedical Engineering*, 2012, 59(10): 2930-2941.
- [9] Association for the Advancement of Medical Instrumentation. ANSI/AAMI EC57:2012 Standard: Testing and reporting performance results of cardiac rhythm and ST segment measurement algorithms [S]. USA: AAMI Press, 2012.
- [10] 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 Linpeng, DONG Jun. Deep learning research on clinical electrocardiogram analysis [J]. *Science China: Information Sciences*, 2015, 45(3): 398-416. (in Chinese)
- [11] AHLSTROM M L, TOMPKINS W J. Digital filters for real-time ECG signal processing using microprocessors [J]. *IEEE Transactions on Biomedical Engineering*, 1985, 32(9): 708-713.
- [12] 高清维,李海鹰,庄镇泉,等. 基于平稳小波变换的心电信号噪声消除方法[J]. *电子学报*, 2003, 31(2): 238-240. GAO Qingwei, LI Haiying, ZHUANG Zhenquan, et al. De-noising of ECG signal based on stationary wavelet transform [J]. *Acta Electronica Sinica*, 2003, 31(2): 238-240. (in Chinese)
- [13] 杨向林,严洪,许志,等. 基于 Hilbert-Huang 变换的 ECG 消噪[J]. *电子学报*, 2011, 39(4): 819-824. YANG Xianglin, YAN Hong, XU Zhi, et al. ECG de-noising based on Hilbert-Huang transform [J]. *Acta Electronica Sinica*, 2011, 39(4): 819-824. (in Chinese)
- [14] VALENTINI Giorgio, MASULLI Francesco. Ensembles of learning machines [A]. *Proceedings of the 13th Italian Workshop on Neural Nets-revised Papers [C]*. London:

- Springer Berlin Heidelberg, 2002; 3 - 20.
- [15] ZHOU Zhi-Hua, WU Jianxin, TANG Wei. Ensembling neural networks: many could be better than all [J]. Artificial Intelligence, 2002, 137: 239 - 263.
- [16] KITTLER Josef, HATEF Mohamad, DUIN Robert P W, et al. On combining classifiers [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1998, 20(3): 226 - 238.
- [17] 徐拥军, 钟玉秋, 曾文斌. 一种基于心电向量的心电波形特征点定位方法 [P]. 中国专利: 201410068351. 6, 2014-02-27.
- [18] MIT-BIH Arrhythmia Database [EB/OL]. <http://www.physionet.org/physiobank/database/mitdb/>. 2015. 6 [2015-09-25].
- [19] ZHANG Jiawei, LIU Xia, DONG Jun. CCDD: an enhanced standard ECG database with its management and annotation tools [J]. International Journal on Article Intelligence Tools, 2012, 21(5): 1 - 26.
- [20] DONG Jun, ZHANG Jiawei, ZHU Honghai, et al. Wearable ECG monitors and its remote diagnosis service platform [J]. IEEE Intelligent Systems, 2012, 27: 36 - 43.
- [21] 朱洪海. 心电图自动识别的关键算法及多体征监护系统研制 [D]. 北京: 中国科学院大学, 2013.
ZHU Honghai. Key algorithms on Computer-Aided Electrocardiogram Analysis and Development of Remote Multi-signs Monitoring System [D]. Beijing: University of Chinese Academy of Sciences, 2013. (in Chinese)
- [22] 王丽苹. 融合领域知识的心电图分类方法研究 [D]. 上海: 华东师范大学, 2012.
WANG Liping. Study on Approach of ECG Classification with Domain Knowledge [D]. Shanghai: East China Normal University, 2012. (in Chinese)

- [23] HAKACOVA Nina, TRAGARDH-JOHANSSON Elin, WAGNER Galen S, et al. Computer-based rhythm diagnosis and its possible influence on nonexpert electrocardiogram readers [J]. Journal of Electrocardiology, 2012, 45(1): 18 - 22.

作者简介



周飞燕 女, 1986 年 4 月出生, 广西崇左人. 博士研究生, 研究方向为计算机辅助心血管疾病诊断.

E-mail: fyzhou2013@sinano.ac.cn



金林鹏 男, 1984 年 6 月出生, 浙江瑞安人. 博士, 研究方向为机器学习.

E-mail: lpjin2012@sinano.ac.cn



董 军 (通信作者) 男, 1964 年 11 月出生, 江苏苏州人. 博士、研究员、博士生导师, 研究方向为人工智能.

E-mail: jdong2010@sinano.ac.cn