

基于集成学习的束支传导阻滞识别方法

徐久强, 张金鹏, 贾玉其, 邵建新
(东北大学 计算机科学与工程学院, 辽宁 沈阳 110169)

摘 要: 为提升基于心电图的左、右束支传导阻滞自动化诊断性能,提出了一种以多导联心电图卷积神经网络模型作为基学习器的集成学习诊断方法. 首先从临床 12 导联同步静态心电图中提取出有效诊断导联数据并分割为若干个多导联单心搏数据切片. 采用自助采样法抽取多个数据子集,并对每个子集以不同方式进行数据扰动后输入基学习器,得到相应的预测模型. 然后以贝叶斯方法作为集成学习的结合策略融合多个模型进行预测. 最后采用投票法结合 1 例心电图中的多个心搏分类结果给出诊断. 实验结果表明,该方法具有较高的灵敏度和特异度,具有临床应用价值.

关 键 词: 心电图;束支传导阻滞;集成学习;卷积神经网络;贝叶斯方法

中图分类号: TP 391.4 **文献标志码:** A **文章编号:** 1005-3026(2020)03-0321-06

Ensemble Learning Based Recognition Method for Bundle Branch Block

XU Jiu-qiang, ZHANG Jin-peng, JIA Yu-qi, SHAO Jian-xin
(School of Computer Science & Engineering, Northeastern University, Shenyang 110169, China. Corresponding author: ZHANG Jin-peng, E-mail: lnsyzjp@163.com)

Abstract: In order to improve the automatic diagnosis performance of left and right bundle branch block based on electrocardiogram (ECG), an ensemble learning method was proposed, while a combination of multi-lead electrocardiogram and convolution neural network model served as the basic learner. Firstly, effective diagnostic lead data is extracted from the clinical 12-lead synchronous static electrocardiogram and divided into slices of multi-lead single heart beat data. Secondly, the bootstrapping method is used to extract multiple data subsets. Each subset would be perturbed and input to the base learner. Afterwards, the corresponding prediction models are obtained. Then, the Bayesian method is used as the combined strategy of ensemble learning to fuse multiple prediction models. Finally, the diagnosis is provided by voting combined with the classification results of multiple beats in an ECG. The experimental results show that the method has high sensitivity and specificity, which has clinical application value.

Key words: electrocardiogram (ECG); bundle branch block; ensemble learning; convolutional neural networks; Bayesian method

心电图的发展历史已经有百余年,经过几代人的努力,心电图已经是判断心脏健康程度、检查各种心律、心肌供血、心肌传导等病症最便捷、最经济的手段. 心电记录的数量随着心电描记技术的广泛采用和信号采集技术的进步显著增长,但传统的心电图人工审阅效率低且误诊率高. 心电图的自动化诊断是一项艰巨的任务,很多企业、高校、科研院所开始进行心电图计算机自动化诊断的研究.

束支传导阻滞是指希氏束分叉以下部位的传导阻滞,束支传导阻滞的准确判断对冠心病等症状有着预警作用. 心肌梗死、心肌损伤等病症的判断依据会受束支传导阻滞判断结果的严重影响,因此准确识别出束支传导阻滞将对其他心脏疾病

的判断起到辅助作用.

1 问题描述

临床 12 导联同步静态心电图是目前医院门诊进行常规检查的主要手段,诊断过程主要是寻找心电信号的特征波形并测量必要参数,然后据此进行病症判断,实质上就是对心电图进行分类.从心电图的表征来说各种心脏疾病的诊断标准因患者的性别、年龄、各种身体自然因素等的不同而呈现细微差异,难以建立统一标准,因此基于统计学习方法的分类策略被广泛应用.心电图分类策略主要有两种:一是提取心电图的特征参数,然后对心电现象进行识别,文献[1-2]提取心电图特征后,采用支持向量机、最优路径森林等方法进行分类,这类方法严重依赖于特征参数提取的准确性;二是根据心电信号的形态进行分类,文献[3-5]分别采用卷积神经网络、自编码器、受限玻尔兹曼机等进行心电信号分类.心电信号具有周期性,采用神经网络对心电信号分类可按照数据单元长度分为单心搏模式和多心搏模式.无论采取何种模式,在给出分类结果后都应聚合为整例心电图的诊断结论.

希氏束分为左右束支,按阻滞类型可分为左束支传导阻滞(LBBB)和右束支传导阻滞(RBBB),束支传导阻滞会导致心肌激动延迟和异常,心电图上表现为 QRS 波群时限延长和形态异常.本文重点研究基于静息 12 导联心电图的束支传导阻滞的自动化诊断,自动诊断结果最后交由医生进行诊断核实,以提高工作效率和准确性.具体研究适用于多导联心电图的卷积神经网络模型(multi-lead convolutional neural network,MLCNN),并以 MLCNN 作为基学习器研究基于集成学习的束支传导阻滞识别方法.

2 基于 MLCNN 的束支传导阻滞心电图集成学习与分类

图 1 所示为本文束支传导阻滞心电图识别方法的整体流程,包含数据预处理、模型训练、集成预测和多心搏诊断 4 个部分.首先将 12 导联心电图分割为单心搏的数据切片作为数据集;然后抽取数据集的 20% 作为测试集保留,其余用于模型训练;基于 bootstrapping 方法从剩余数据中抽取若干个子集,每个子集按照 8:2 的比例分配给训练集和验证集.本文以 3 个模型集成为例,获取 3

个数据子集 dataset 1, dataset 2 和 dataset 3. 3 个数据子集分别采用不同的滤波算法进行处理,处理后输入 MLCNN,训练得到 3 个(model 1, model 2 和 model 3)表现良好但具有差异的模型.接着将子集中预留的验证集输入 3 个模型并用贝叶斯方法融合 3 个模型的输出作为单心搏分类结果.最后采用简单投票法将 1 例心电图的多个心搏分类结果结合起来得到诊断结论.

2.1 心电数据预处理

本文使用的心电数据时长为 10 s,采样频率为 500 Hz,组织为 $12 \times 5\,000$ (12 导联 $\times 500$ Hz $\times 10$ s)的矩阵,一切操作针对该矩阵进行.心电信号是体表弱电生理信号,极易受到噪声干扰,其中由肌肉收缩、呼吸、电极位置变化等引起的基线漂移严重影响心电图波形测量.在数据预处理阶段,首先采用文献[6]提出的形态学滤波方法对心电信号进行基线矫正以排除基线漂移对后续波形检测的影响;然后利用文献[7]提出的单导联心电图波形检测方法对各导联分别进行检测,得到 12 导联所有心搏的 P 波、QRS 和 T 波的起止点及峰值点信息.随后综合 12 导联信息,对于第 k 个心搏,以第 $k-1$ 个心搏各导联最晚的 T 波结束点作为起始点,以当前心搏的各导联最晚的 T 波结束点作为终止点,得到若干个长度不等的 12 导联单心搏数据切片(去除第一个不完整的心搏).有研究表明束支传导阻滞依靠 I, V1 和 V6 3 个导联就可以准确识别^[8],所以只提取这 3 个导联数据,并且将单心搏的采样点数重采样归一化到 400 个,得到若干 3×400 的矩阵数据单元.

2.2 MLCNN 模型及其训练

单导联心电信号是一维时间序列,利用一维卷积神经网络模型^[9]进行分类较为常见. Jun 等^[10]将心电信号转换为二维灰度图像,并利用二维卷积神经网络模型进行分类,12 导联心电图表示为 $12 \times 5\,000$ 的二维矩阵.由于心电图同导联内(横向)相互关联,而不同导联间(纵向)相对独立,这不同于二维图像结构,因此本文考虑多导联心电数据的特殊性,设计了 MLCNN 模型,基础卷积单元和网络结构如图 2、图 3 所示.

将 I, V1 以及 V6 3 个导联的单心搏心电数据组成 3×400 的矩阵,设置相应的一维卷积核,使其按行卷积得到 feature map. 由基础卷积单元构建多导联心电图的卷积神经网络模型 MLCNN,MLCNN 具有 13 层网络结构:6 个卷积层、4 个池化层和 3 个全连接层.整个 MLCNN 除池化层和激活层外有 9 层需要训练参数,前 6 层为卷积层,

后 3 层为全连接层,共计 62 723 个参数. 输出层采用 Softmax 函数进行分类.

训练使用 mini-batch 基于反向传播的梯度下降法来优化多项逻辑回归目标. 批数量为 256,在前两个全连接层 dropout 为 0.5 ,学习率为 0.01 ,

且当验证集停止提升时以 10 的倍数衰减. 同时,初始化权重取样于标准高斯分布,偏置项初始化为 0. 前 3 个卷积层使用 1×5 的卷积核,步长为 3,后 3 个卷积层使用 1×3 的卷积核,步长为 1 ,激活函数使用 ReLU.

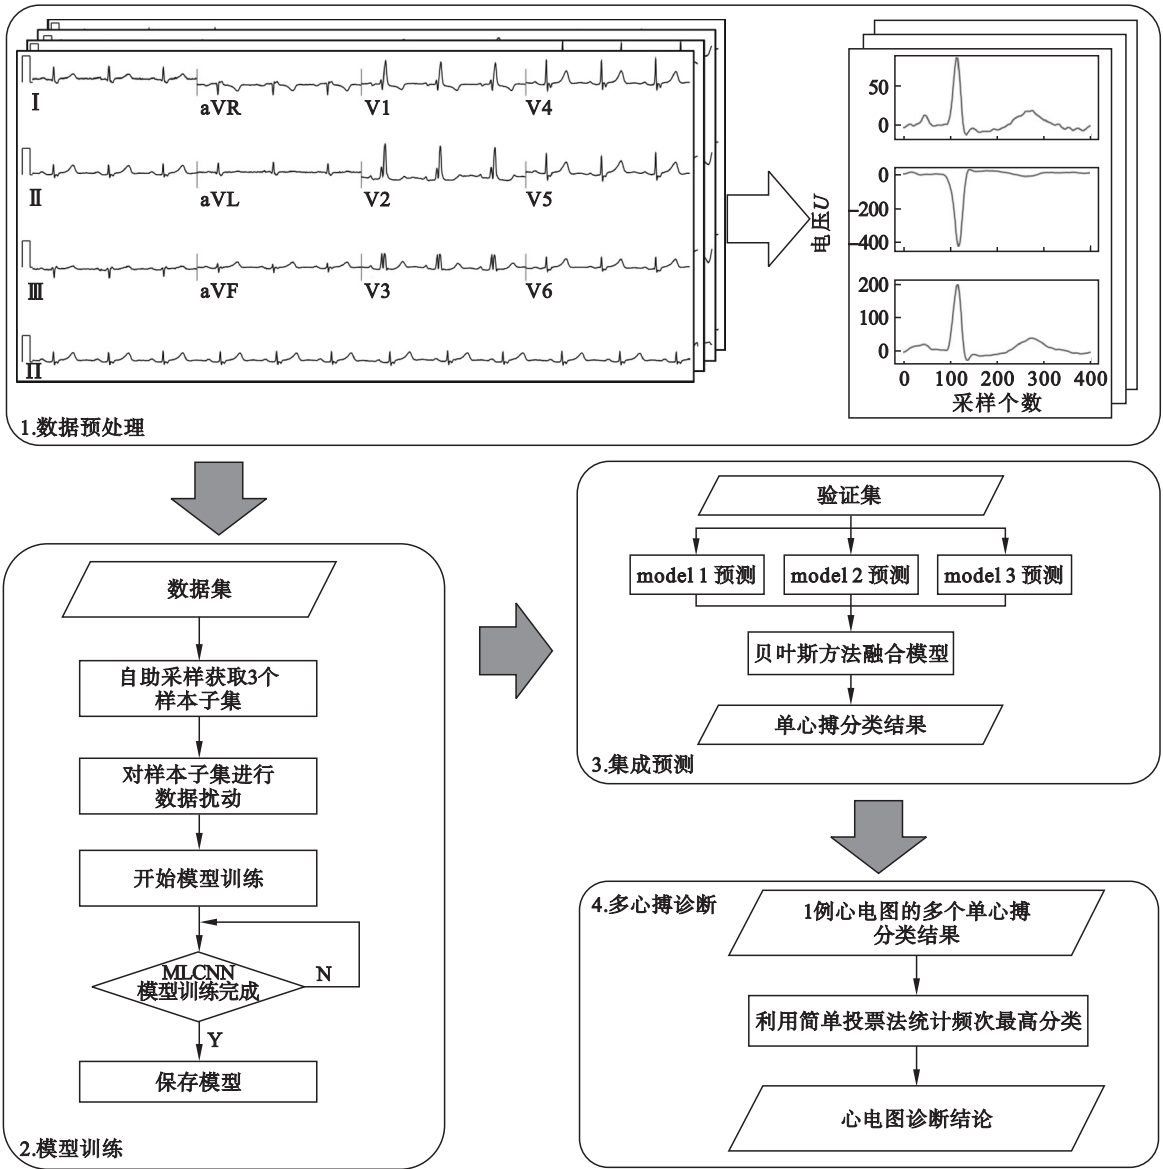


图 1 心电图分类整体流程
Fig. 1 Overall process of ECG classification




图 2 卷积单元
Fig. 2 Convolution unit

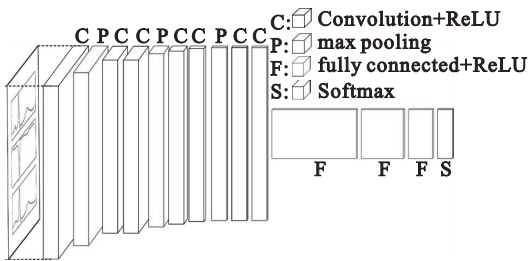


图 3 MLCNN 模型的结构
Fig. 3 Structure of the proposed MLCNN model

对数据集 dataset 1, dataset 2 和 dataset 3 分别进行不同的滤波操作(FIR 滤波、IIR 滤波和 0.5 ~ 58 Hz 的带通滤波). 将 3 个经过滤波后的数据集分别输入 MLCNN, 训练得到 model 1, model 2 和 model 3. 以下是训练过程, 图 4 为训练流程图.

- 步骤 1 初始化神经网络的权重和偏置.
- 步骤 2 随机选择小批量数据样本 (D_k, L_k) 送入神经网络, D_k 为数据, L_k 为分类标签.
- 步骤 3 按照式(1)计算误差 E , 并计算参数调整量. 式中 d_k 是目标矢量, y_k 是输出矢量.
- $$E = \frac{1}{2} \sum_{k=0}^{n-1} (d_k - y_k)^2. \tag{1}$$
- 步骤 4 判断是否满足训练目标要求, 如果不满足要求, 转步骤 5, 否则保存参数, 训练完成.
- 步骤 5 判断是否连续五轮训练更新权重没有引起损失函数的值变化. 如果模型性能没有提升则变更学习率, 更新权重, 转步骤 2; 否则更新权重再转步骤 2.

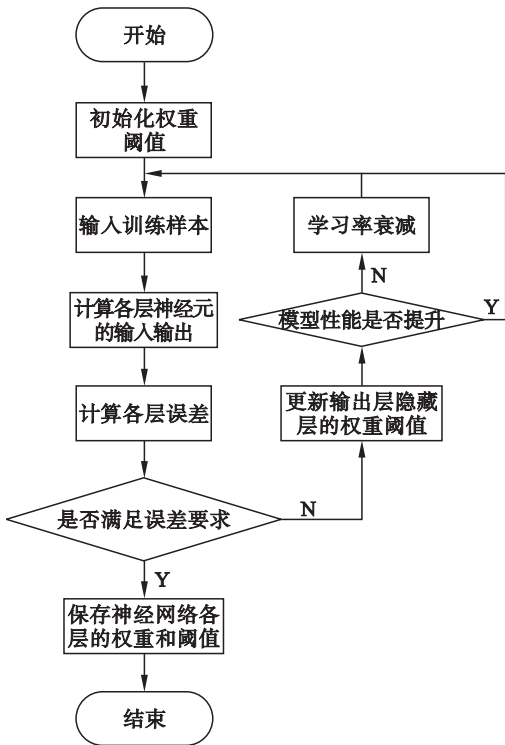


图 4 模型训练流程图
Fig. 4 Flowchart of model training

2.3 单心搏分类的集成

为了增强分类性能, 本文采用以 MLCNN 作为基学习器的同质集成学习思想, 将自助采样的数据集在数据差异化处理后分别输入 MLCNN 进行训练, 在得到的预测模型基础上用贝叶斯方法进行融合以实现集成学习. 基于 model i 融合后的分类结果 result 由式(2)确定, $P(y = j | \text{model } i)$ 是

第 i 个分类器 model i 给出的结果属于类别 j 的概率.

$$\left. \begin{aligned} P(y = j | \text{model } 1, 2, 3) &= \\ \frac{1}{3} \sum_{i=1}^3 P(y = j | \text{model } i), \\ \text{result} &= \operatorname{argmax} \{ P(y = j | \text{model } 1, 2, 3) \}. \end{aligned} \right\} \tag{2}$$

2.4 束支传导阻滞的多心搏决策

一般束支传导阻滞在心电图的所有心搏都会体现, 可以将 1 例心电图中多个心搏的分类结果联合起来给出诊断结论. 假设 1 例心电图中共有 n 个心搏, 每个心搏的分类结果有三种为 A, B 和 C, 本文采用简单投票法对心搏分类情况进行统计, 票数最多的分类即为心电图的最终结论.

3 实验结果及分析

3.1 实验数据集及评价指标

本文实验数据来自中国医科大学附属第一医院的临床资料, 由心脏科医生给出诊断标注. 实验使用了 5 250 例心电图, 共计 50 151 个心搏单元. 其中 3 500 例心电图用于单心搏分类模型的训练与测试, 1 750 例心电图用于多心搏投票预测(见表 1). 为验证本文方法的有效性, 从单心搏分类模型数据集的每类中抽取 20% 用作心搏分类功能测试, 剩余部分用于训练. 表 1 展示了数据的分布情况, 表中的其他类包含除 LBBB 和 RBBB 外的其他心电图.

本例分类模型为三分类, 假定任一分类为正例, 则另外两类为负例. 由此可针对每个类别分别统计 4 个基本统计量 TP(true positive), FP(false positive), FN (false negative) 和 TN (true negative), 由以上统计量可以计算灵敏度、特异度、正确率和准确率等 4 个性能评估指标. 文献 [10] 给出了参数含义和计算方法.

3.2 实验结果分析

表 2 给出了 3 个分类模型和模型融合后在测试集上得到的混淆矩阵, 可以看出任一模型分类性能良好且模型间具有差异. 由混淆矩阵计算评价参数, 得到表 3, 集成后 3 种心搏识别的正确率分别为 98. 40% , 99. 01% 和 98. 06% , 与单一分类器相比均有所提升, 灵敏度、特异度以及准确率集成后的结果没有显著变化. 整体正确率由混淆矩阵中所有类别预测结果与标签一致的样本数除以总样本数计算得到, 3 个基础分类器的整体正确率分别为 97. 18% , 94. 32% 和 96. 88% , 集成后的

正确率提升为 97.73%。表 4 所示为 1 750 条心电图测试样例结合多心搏进行诊断的测试结果,总正确率为 98.80%,且具有高灵敏度和特异度。实验结果表明本文采用的基于集成学习的束支传导阻滞识别方法可以有效识别左、右束支传导阻滞心电图,该方法具有较好的诊断效能。

表 1 数据分布表
Table 1 Data distribution table

分类名称	单心搏分类模型训练与测试				多心搏决策	
	心电图数	心搏数	训练样本数	测试样本数	心电图数	心搏数
LBBB	1 000	9 029	7 223	15 000	500	4 251
RBBB	1 000	10 016	8 013	1 806	500	4 768
其他	1 500	14 648	11 718	2 003	750	7 439
总计	3 500	33 693	26 954	6 739	1 750	16 458

表 2 预测混淆矩阵
Table 2 Confusion matrix of prediction results %

类别	model 1			model 2			model 3			集成			
	LBBB	RBBB	其他	LBBB	RBBB	其他	LBBB	RBBB	其他	LBBB	RBBB	其他	
Label	LBBB	1 691	21	94	1 723	19	64	1 684	20	102	1 721	22	63
	RBBB	0	2 001	2	0	1 960	43	0	1 970	33	0	1 998	5
	其他	20	53	2 857	89	168	2 673	21	34	2 875	23	40	2 867

表 3 实验评价参数
Table 3 Experimental evaluation parameters %

参数	model 1			model 2			model 3			融合		
	LBBB	RBBB	其他	LBBB	RBBB	其他	LBBB	RBBB	其他	LBBB	RBBB	其他
灵敏度	93.63	99.90	97.51	95.40	97.85	91.23	93.24	98.35	98.12	95.29	99.75	97.85
特异度	99.59	98.44	97.48	98.20	96.05	97.19	99.57	98.86	96.46	99.53	98.69	98.21
正确率	98.00	98.87	97.49	97.45	96.59	94.60	97.88	98.71	97.18	98.40	99.01	98.06
准确率	98.83	96.43	96.75	95.09	91.29	96.15	98.77	97.33	95.51	98.68	96.99	97.68

表 4 多心搏联合预测结果
Table 4 Prediction results of the combined multiple beats

类别		预测			灵敏度/%	特异度/%	正确率/%	准确率/%
		LBBB	RBBB	其他				
标签	LBBB	496	1	3	99.20	99.68	99.66	99.20
	RBBB	0	494	6	98.80	99.36	99.20	98.41
	其他	4	7	739	98.53	99.10	98.86	98.80

4 结 语

本文提出了以 MLCNN 作为基学习器,通过贝叶斯方法融合多个模型进行多导联单心搏心电图分类的集成学习方法,并采用简单投票法结合心电图的多个心搏预测整例心电图的最终诊断.3 个基学习器的多导联单心搏分类正确率分别为 97.18%,94.32% 和 96.88%,集成后提升为 97.73%,针对整例心电图的诊断正确率为

98.80%。实验结果表明 MLCNN 是一个有效的多导联心电图分类模型,本文所提方法可以有效识别左、右束支传导阻滞心电图,具有临床应用价值。

参考文献：

[1] Wang W F, Yang C Y, Wu Y F. SVM-based classification method to identify alcohol consumption using ECG and PPG monitoring[J]. *Personal and Ubiquitous Computing*, 2018, 22(2):275 – 287.