

# 基于可穿戴设备的心电图自适应分类算法研究

樊敏<sup>1</sup> 王晓锋<sup>1</sup> 孟小峰<sup>2</sup>

(山西医科大学汾阳学院 山西 汾阳 032200)<sup>1</sup> (中国人民大学信息学院 北京 100872)<sup>2</sup>

**摘要** 目前,心血管疾病已成为全球人类非传染性死亡的主要原因,死亡人数约占全球死亡总人数的 1/3,且患病人数逐年增加。可穿戴设备被用于对心电图进行自动分类,以实现对心血管疾病的早监测、早预防。随着边缘机器学习和联邦学习的兴起,小型机器学习模型成为了人们关注的热点。针对可穿戴心电图设备低配置、低功耗及个性化的特点,文中研究了一种基于 LSTM 的轻量级网络结构,并采用自适应算法来优化病人个体的心电图分类模型。该模型利用 MIT-BIH 公开数据集开展实验,将 VEB 和 SVEB 的分类效果与其他相关研究进行了比较。实验结果表明,所提算法的模型结构简单且分类识别率高,能够满足可穿戴设备对病人心电图监测的需求。

**关键词** 可穿戴设备,心电图分类,自适应,LSTM

中图分类号 TP181 文献标识码 A DOI 10.11896/jsjcx.190500181

## Study on Patient-adaptive Algorithm for ECG Classification Based on Wearable Devices

FAN Min<sup>1</sup> WANG Xiao-feng<sup>1</sup> MENG Xiao-feng<sup>2</sup>

(Fenyang College of Shanxi Medical University, Fenyang, Shanxi 032200, China)<sup>1</sup>

(School of Information, Renmin University of China, Beijing 100872, China)<sup>2</sup>

**Abstract** At present, cardiovascular diseases have become the main cause of global non-communicable death, death toll accounts for about one third of the total toll of death in the world, and the number of patients is increasing year by year. Wearable devices is used to automatically classify electrocardiogram to facilitate the early monitoring and prevention of cardiovascular diseases for patients. With the rise of edge machine learning and federated learning, small machine learning models have become a hot issue. According to the characteristics of wearable electrocardiogram equipment such as low configuration, low power consumption and personalization, this paper studied a lightweight network model based on LSTM, and used adaptive algorithm to optimize the ECG classification model of individual patients. The experiment is conducted by using the MIT-BIH open dataset. And compared with the current studies on the detection performance of VEB and SVEB, the experiment results show that the proposed algorithm has simple model structure and high classification performance, which can meet the requirement of ECG monitoring for patients by wearable devices.

**Keywords** Wearable devices, ECG classification, Adaptive, LSTM

## 1 引言

心血管疾病是全球人类非传染性死亡的主要原因,约占全球死亡总人数的 1/3。根据 WHO(World Health Organization)报告,预计到 2030 年,心血管病的死亡人数将上升到 2300 万。《中国心血管病报告 2018》概要<sup>[1]</sup>中指出,心血管疾病的死亡率仍居患病死亡率的首位,中国患心血管疾病的人数达 2.9 亿,而且在逐年持续增加,因此及早防治心血管疾病显得必要且紧迫。

心律失常是一种常见的心血管疾病,会增加中风或心脏性猝死的风险。心电图(Electrocardiograph, ECG)是心血管疾病诊断和心律失常风险评估最有效的工具,它捕捉人体表面的心脏电活动,为治疗和诊断提供有价值的信息。心律失

常往往是间歇性的,需要对心电图进行长期监测,但人为阅读心电图的工作强度大,且容易造成失误。因此,亟需一种可靠、可用性较强且能自动识别心律失常的方法来对病人的健康情况进行监测,可穿戴心电图设备的出现解决了这一问题,其能够方便地收集并记录病人的心电数据。

现有的研究通常是将病人的健康数据发送到云服务器,再将分析结果反馈到终端设备。这种计算会受到连接、延迟、带宽以及隐私等问题的影响,不能满足实时监测的需求;更重要的是,病人个体的心电图差异性较大,现有的心电图分类模型泛化能力较差,且性能不稳定,不能满足实际应用的需求。

随着边缘机器学习和联邦学习的提出<sup>[2-3]</sup>,人们开始研究小型机器学习模型,其可以在资源有限的平台(比如智能手机、可穿戴设备以及其他物联网设备等)上有效运行,而且数

到稿日期:2019-05-31 返修日期:2019-07-28

樊敏(1982-),女,硕士,副教授,CCF 会员,主要研究方向为数据库、机器学习, E-mail: wsfmq@163.com(通信作者);王晓锋(1978-),男,硕士,高级实验师,主要研究方向为数据库、数据挖掘;孟小峰(1964-),男,博士,教授,博士生导师,主要研究方向为大数据管理、数据集成。

据保留在可穿戴设备上,避免了隐私泄露的问题。本文提出的模型是一种面向可穿戴设备的基于 LSTM 的轻量级模型,通过自适应算法,利用病人个体的心电信号来训练本地分类模型,能够对病人心电图进行实时监测。

## 2 相关工作

在心电图自动分类问题上,大多数算法首先利用信号处理技术进行特征提取,将其组成特征向量。方法包括形态特征表示、频域分析、小波变换等。然后,采用支持向量机、神经网络、聚类分析、随机森林等构建分类器,对特征向量进行学习,实现心电信号的分类。但是,利用训练好的分类器对新的病人心电信号进行分类时,其性能不稳定,且分类识别率不高。其原因在于心电图波形在病人个体和病人群体中存在较大的个体差异<sup>[4]</sup>。例如,每个人的心率是不一样的,正常心率是 60~100 次/min,即一个完整的正常心电图波形经历的时间大约为 0.6~1 s 不等,表现在心电图上的 RR 间期不同,每个人的心电图都有自己的特征,同一类别的心电波形对于不同的个体可能存在显著差异。因此,分类模型往往由于泛化能力较差而不能满足实际需求。

由专家协助的病人心电图自适应方法被证明是有用的,相关文献报告了该方法比全自动分类器具有更好的性能。心电图可穿戴设备对病人个体的心脏状态进行监测,能非常便捷地获取病人的心电数据,而且病人特异性样本将有助于训练一个性能良好的本地模型。因此,在可穿戴心电设备监测场景中,更适合采用病人心电图自适应算法来提高个体心电图的分类性能。Hu 等<sup>[5]</sup>提出了一种采用人工神经网络来学习心电信号特征,并利用了专家协助进行的病人适应性心跳分类方法;同时认为,与性能增强的潜在收益相比,获取专家对少量心跳标注的成本是相当小的。Chazal 等<sup>[6]</sup>利用线性判别分类器对心电图形态、心跳间隔和 RR 间期等不同时域的特征进行病人自适应心跳分类。Jiang 等<sup>[7]</sup>基于块神经网络模型,采用 Hermite 变换系数选择心电信号的时间特征,来进行病人个性化心电信号的分类。Ince 等<sup>[8]</sup>提出了一种基于形态学的小波变换特征,其利用主成分分析将形态小波变换特征投影到低维特征空间,采用人工神经网络构建心跳自动分类系统。上述算法都利用较少的特定病人的训练数据,通过再训练优化分类器来适应病人个体心电图模式的显著变化,提高了分类精度,但这些心电信号的特征需要人工设计并进行提取,然后选择某些特征进行学习。实验表明,心电分类性能的好坏很大程度上取决于心电信号的表征能力,如果重要的特征没有被选中,即使是最好的分类器,也可能产生较差的性能。

为了实现特征的自动提取,最近有研究者提出了基于深度学习的算法。深度学习也称为表征学习,是指从输入数据中自动学习一个好的特征表示,其优势在于可以从大量数据中自动学习特征而无须人工设计。Rajpurkar 和 Hannun 等<sup>[9-10]</sup>采用了 34 层卷积神经网络(Convolutional Neural Networks, CNN),利用来自 53 549 位病人的 91 232 条记录组成的大型数据集,将心电信号分为包括窦性心律在内的 11 种心律及噪声。Jun 等<sup>[11]</sup>提出了具有 11 层二维卷积的 CNN 算

法; Acharya 等<sup>[12]</sup>利用数据增强来解决数据不平衡问题,并采用 9 层 CNN 实现心电图分类。Luo 等<sup>[13]</sup>针对人体无线传感器网络设备,利用时频表示特征,训练深度神经网络(Deep Neural Network, DNN)的分类器,并利用病人个体的少量心跳样本对模型进行微调,实现了特定于病人的心跳分类器。这些算法都是计算密集型,不适合在可穿戴设备上运行。因此,低配置、低功耗的可穿戴设备,需要轻量级、计算复杂度小的分类器。

Kiranyaz 等<sup>[14]</sup>提出了一种基于一维卷积神经网络的病人自适应算法。在该算法中,相邻 3 个心跳作为网络的输入,目的是获取心跳在时域上的依赖关系。长短时记忆(Long Short-Term Memory, LSTM)网络具有很好的捕捉时间依赖的能力,在处理心电信号的时间序列数据方面具有很大的优势。Oh 等<sup>[15]</sup>提出了一种将 CNN 和 LSTM 相结合的自动分类系统,该系统在变长的心电信号上表现出较高的分类性能。最近, Saadatnejad 等<sup>[16]</sup>提出了基于单向的 LSTM 网络模型,该模型由模型  $\alpha$  和模型  $\beta$  构成,共使用了 3 个双层单向 LSTM 的网络结构。首先,提取小波特征,计算 10 个 RR 间期的平均值,将其与心电图截取的心拍作为输入分别训练模型  $\alpha$  和模型  $\beta$ ; 然后,将两个模型的输出进行概率混合,形成最终的分类结果。而本文提出的算法采用单层双向 LSTM 的网络结构,充分利用心电信前后采样点的时序依赖特征,自动提取特征,网络结构更加轻量级,计算复杂度更低,而且对心电信号分类的准确率较高,更能满足在处理能力有限的可穿戴设备上实时监测心电信号的要求。

## 3 自适应分类算法描述

### 3.1 基于双向 LSTM 的网络结构

心脏在收缩跳动过程中,心肌先发生电激动,然后心肌机械性收缩,身体不同部位的表面产生了电位差。应用心电图设备记录心肌电流随时间的变化情况,从而形成有规律的心电图波形,也称为 P-QRS-T 波,如图 1 所示。

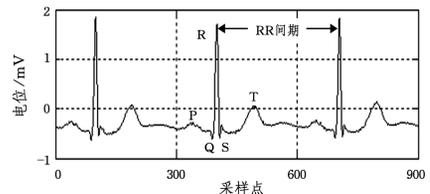


图 1 心电图波形

Fig. 1 ECG waveform

长短时记忆网络是近年来在序列数据分析中被广泛使用的一种循环神经网络,在语音识别、语言模型以及机器翻译等方面取得了突破性进展。

心肌电流随时间变化形成的有规律心电波形具有很强的时间依赖性,而且一个心跳中的各分段波形之间的位置关系密切,如 P 波在 QRS 复合波之前, T 波出现在 QRS 复合波之后。因此,在心电图分类问题上,采用 LSTM 网络结构的循环神经网络比其他神经网络表现更好,而且采用双向的 LSTM 网络比单向的 LSTM 网络更有效。在自适应分类算法中,网络结构如图 2 所示。网络结构包含输入层、双向 LSTM 层、Softmax 层以及输出层。

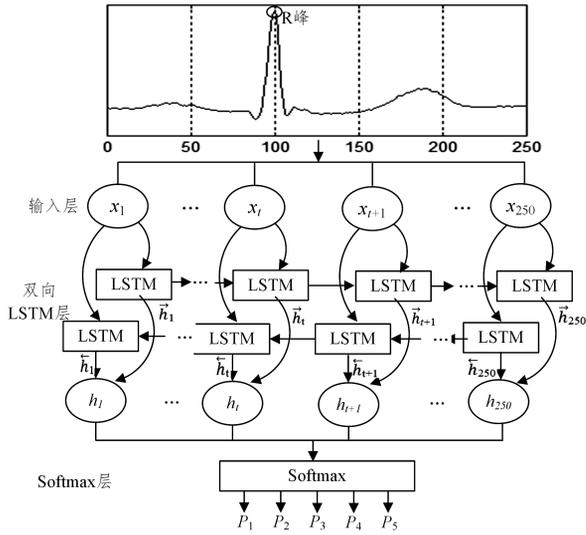


图2 网络结构图

Fig. 2 Network structure diagram

### 3.1.1 输入层

网络的第一层是输入层,主要进行 QRS 波检测和心电图分割。利用 Pan-Tompkins 算法<sup>[17]</sup>对心电图原信号进行高频滤波,消除各种噪声和伪影(基线漂移、电源工频干扰、肌肉收缩等)的影响,通过一系列的信号处理检测 QRS 波,并对心电信号进行分割截取,得到若干个心拍。分割方法为:由 QRS 波检测得到 R 峰所在的位置,以 R 峰位置作为基准点,向前取 99 个采样点,向后取 150 个采样点,将连同 R 峰在内的共 250 个采样点作为一个心拍进行分割。每个采样点的取值表示心电信号在该时刻的电位值。在采样率为 360 Hz 的频率下,以 R 峰为基准点取前后共 250 个采样点(相当于 0.7 s)的心电信号,其中包含了一次心跳的关键波形即 P 波、QRS 波以及 T 波。如果分割时间过短,则不足以表征一次心跳的各个阶段;时间过长,则会使心拍包含多余的心跳信息,干扰分类结果。

### 3.1.2 双向 LSTM 层

网络的第二层是双向 LSTM 层。将每个心拍的 250 个采样点的电位值组成一维向量,并将其作为输入传入双向 LSTM 网络中,自动提取每个心拍波形在时序和电位信息两方面的特征,充分地学习了不同类型心跳的重要特征。

LSTM 网络是由一组记忆单元(Memory Block)组成的链式循环网络结构,每个记忆单元拥有 3 个门结构——遗忘门、输入门和输出门,如图 3 所示。通过这 3 个门来控制单元状态的保持和更新,并进行状态传递和结果输出。

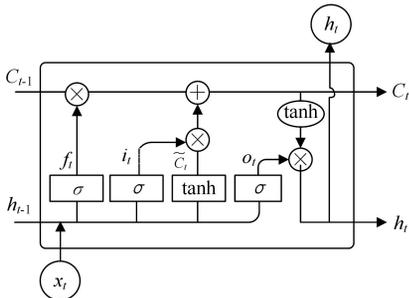


图3 LSTM 基本单元

Fig. 3 LSTM basic unit

双向 LSTM 网络由两个单向的 LSTM 网络构成,分正向和反向两个方向进行信息传递。在图 2 中可以看到,在每一时刻  $t$ ,输入层会同时提供给这两个方向相反的 LSTM 网络。由于这两个网络中的神经元互不相连,因此两个 LSTM 网络独立计算各自在该时刻的新状态和输出。将两个单向 LSTM 网络的输出进行拼接,形成最终的输出。下面以一个心拍作为输入,来描述第  $t$  个采样点通过 LSTM 单元正向传递得到新状态  $\vec{C}_t$  和输出  $\vec{h}_t$  的过程。计算过程如下:

$$f_t = \text{sigmoid}(W_f[\vec{h}_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \text{sigmoid}(W_i[\vec{h}_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c[\vec{h}_{t-1}, x_t] + b_c) \quad (3)$$

$$\vec{C}_t = f_t \cdot \vec{C}_{t-1} + i_t \cdot \tilde{C}_t \quad (4)$$

$$o_t = \text{sigmoid}(W_o[\vec{h}_{t-1}, x_t] + b_o) \quad (5)$$

$$\vec{h}_t = o_t \cdot \tanh \vec{C}_t \quad (6)$$

其中,  $x_t$  表示当前时刻采样点的电位值,作为网络中的一个输入;  $\vec{h}_{t-1}$  是上一时刻的输出;  $\vec{C}_{t-1}$  是上一时刻的状态;  $W$  是权重,  $b$  是偏置项。首先,“遗忘门”利用  $x_t$  和  $\vec{h}_{t-1}$ ,通过 sigmoid 函数计算  $f_t$ ,以此决定  $\vec{C}_{t-1}$  中信息的遗忘和保留;然后,“输入门”利用  $x_t$  和  $\vec{h}_{t-1}$ ,通过 sigmoid 函数计算  $i_t$ ,以此决定候选态  $\tilde{C}_t$  中的哪些信息更新到状态  $\vec{C}_t$  中;最后,“输出门”利用  $x_t$  和  $\vec{h}_{t-1}$  计算  $o_t$  与新状态  $\vec{C}_t$ ,得到第  $t$  个采样点的输出和向下一时刻传递的特征  $\vec{h}_t$ 。

反向的 LSTM 传递与正向的类似,从一个心拍的最后一个采样点开始,依次进行计算,得到新状态  $\vec{C}_t$  和特征  $\vec{h}_t$ ,并向前一时刻传递,同时输出  $\vec{h}_t$ 。将正向 LSTM 输出的特征  $\vec{h}_t$  与反向 LSTM 输出的特征  $\vec{h}_t$  进行拼接合并,得到第  $t$  个采样点的完整特征。该过程的公式表示如下:

$$h_t = [\vec{h}_t, \vec{h}_t] \quad (7)$$

在双向 LSTM 层中,隐藏层的大小为 1,该层通过正向和反向两个 LSTM 网络提取每个心拍的特征以及采样点间在时序上的依赖关系,并将输出拼接成一维特征向量  $H$  作为 Softmax 层的输入。

### 3.1.3 Softmax 层

网络的最后一层是 Softmax 层,该层利用全连接操作和 Softmax 函数对每个心拍进行分类。每个心拍的特征向量  $H$  经过全连接后,通过 Softmax 函数计算得到 5 个类别的概率,取概率最大的类别作为最终预测结果的类别。具体计算公式如下:

$$P(y|\mathbf{H}) = \text{Softmax}(W * \mathbf{H} + b) \quad (8)$$

$$y = \underset{\wedge}{\text{argmax}}[P(y|\mathbf{H})] \quad (9)$$

其中,  $P(y|\mathbf{H})$  表示心拍特征属于某一类别的概率,表示最终的预测类别。

### 3.1.4 网络复杂度分析

在双向 LSTM 层中,利用权重  $W$  和偏置项  $b$  计算  $f_t, i_t, \vec{C}_t$  和  $o_t$ ,所以参数的数量为  $2 * 4 * \text{Hidden\_size} * (\text{Input\_}$

$size + Bias + Output\_size$ )。LSTM 的每个时刻处理的是心拍中的一个采样点,  $Input\_size$  和  $Output\_size$  都为 1,  $Bias$  也为 1, 该层的  $Hidden\_size$  为 1, 所以参数共 24 个。

在 Softmax 层,  $Input\_size$  为  $500 \times 1$ , 有 5 个神经元, 即  $Output\_size$  为 5,  $Bias$  为 5, 因此该层参数共 2505 个。

在可穿戴设备场景下, 利用该网络模型进行心跳分类时, 网络的输入是由心拍数据构成的一维向量, 与各参数进行乘积、求和运算, 其运算强度不大, 可以在可穿戴设备上完成。

### 3.2 自适应算法

一个已训练好的分类器往往在病人心电图分类上的表现并不稳定, 即便构建一个大型的心电数据库来训练分类器, 也同样不能保证每一位病人心电图自动分类的效果, 而且开发和维护的成本极高。基于可穿戴设备专门采集病人个体数据的特点, 可以使分类算法适应病人个体心电图的特异特征, 将分类器细化到每位病人。

自适应算法借鉴迁移学习中领域自适应的方法, 利用数据、任务和模型之间的相似性, 将在原域学习过的模型应用于目标域, 并利用目标域的少量标签进行参数微调, 以实现目标域模型的优化, 得到适应病人特征的分类器。

自适应分类算法将模型训练分为全局训练和自适应训练两个步骤, 如图 4 所示。在全局训练阶段, 利用较大的 ECG 数据集训练全局模型, 并将其作为初始模型进行可穿戴设备的初始化配置。在自适应训练阶段, 首先利用初始模型将可穿戴设备获取的病人的少量心拍数据进行预分类标注, 然后将预标注结果给专家校正后对初始模型进行再训练, 微调相关参数, 优化分类模型, 最终得到适应病人心电图特征的本地模型。该算法利用训练好的本地模型对病人心电图的每一次心跳进行实时分类和监测, 有效提高了病人个体心电图识别的准确率。

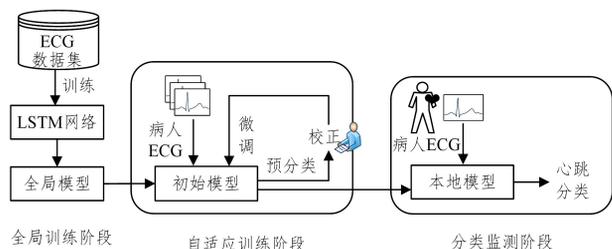


图 4 心电图的自适应过程

Fig. 4 Daptive process of ECG

自适应算法的优势在于: 使用了一小部分个体样本来最大化分类的性能, 降低了对初始模型通用性的要求。由于训练一个面向不同病人都能较好地进行心跳分类的通用模型是困难的, 因此在实际心电监测的应用场景中, 专家协助是非常必要的, 其保证了可穿戴心电设备能可靠且有效地对病人的健康状况进行监测。

## 4 实验及结果分析

### 4.1 实验数据

本实验采用 MIT-BIH 心律失常数据库, 该数据库是美国医疗仪器促进协会 (Association for the Advancement of Medical Instrumentation, AAMI)<sup>[18]</sup> 推荐用于医疗设备验证最常

用的, 也是进行心电图分类研究使用最广泛的, 更重要的是它是 AAMI 标准中唯一考虑了所有 5 类心律失常的数据库。

MIT-BIH 心律失常数据库是由麻省理工学院 (Massachusetts Institute of Technology, MIT) 和美国麻萨诸塞州波士顿医院 (Beth Israel Hospital, BIH) 在 1980 年共同创建并发布的。数据集中包含 48 条充分标注的 30 min 长度的双通道心电信号, 采样率为 360 Hz。每条记录由两个信号组成, 一个是所有记录都有的导联 II, 另一个是 V1, V2, V4 或 V5 导联之一。导联 II 除了显示最重要的 P 波、QRS 波和 T 波之外, 还突出显示了心跳的各个部分, 如图 1 所示。导联 II 是诊断心脏病最常用的导联之一, 而且普遍用于心电图可穿戴设备中, 因此采用 MIT-BIH 数据库的导联 II 数据作为本算法的实验数据集。

该数据库大约包含了 10 万次的心跳, 每一次心跳都由两名或两名以上的心脏病专家独立标注, 共有 15 种不同的心跳类型。由于其中正常搏动的心跳有 74 962 个, 其他类型的心跳数量较少, 如房性逸搏有 16 个, 室上性早搏只有 2 个, 数据不能满足 15 种心跳分类器的训练要求, 因此根据 AAMI 建议<sup>[18]</sup> 将这 15 种心跳分为 5 大类用于设备或方法的检测。

(1) N(Normal)类: 包含起源于窦房结的心律, 如正常搏动、左束支传导阻滞、右束支传导阻滞、房性逸搏、交界性逸搏等。

(2) SVEB(Supra Ventricular Ectopic Beat)类: 包含室上异位心律, 如房性早搏、异常房性早搏、交界性早搏、室上性早搏或者异位心搏等。

(3) VEB(Ventricular Ectopic Beat)类: 包含心室异位心律, 如室性早搏、室性逸搏等。

(4) F(Fusion Beat)类: 正常搏动和 VEB 搏动的融合心律。

(5) Q(Unknow Beat)类: 未分级心律和起搏器心律。

由于 102, 104, 107 和 217 这 4 条记录使用了心脏起搏器, 根据 AAMI 标准建议<sup>[18]</sup> 以及相关文献的处理办法将其去除。Chazal 等<sup>[6, 13, 19]</sup> 提出将其余 44 条记录分为两个数据集 DS1 和 DS2, 每个数据集包含 22 条记录, 大约 5 万次心跳, 并混合了常规和复杂的心律失常记录。DS1 包含了 101, 106, 108, 109, 112, 114, 115, 116, 118, 119, 122, 124, 201, 203, 205, 207, 208, 209, 215, 220, 223, 230 共 22 条记录; DS2 包含了 100, 103, 105, 111, 113, 117, 121, 123, 200, 202, 210, 212, 213, 214, 219, 221, 222, 228, 231, 232, 233, 234 共 22 条记录。

DS1 作为全局模型的训练集, 根据 AAMI 建议, 允许使用每个病人心电信号最长为 5 min 的心跳进行训练, 所以截取 DS2 中每条记录前 5 min 的心电图数据作为自适应训练集, 剩余部分的心电图数据用于心跳分类测试。

利用 Pan-Tompkins 算法<sup>[17]</sup>, 将 DS1 和 DS2 中的心电信号进行一系列数据处理, 对心电图原信号进行高频滤波, 消除噪声和伪影的影响, 通过 QRS 检测得到 R 峰位置, 并将其作为基准点, 向前取 100 个采样点, 向后取 150 个采样点, 共 250 个采样点构成 1 个心拍。利用该方法将一系列心电信号分割成若干心拍。各数据集经过处理后的心拍数量如表 1 所列。

表1 数据集的心拍数

Table 1 Heart beats of datasets

数据集	N	SVEB	VEB	F	Q
全局训练集	45866	940	3788	415	8
自适应训练集	7317	228	524	100	0
测试集	36913	1600	2633	288	7

#### 4.2 实验结果与分析

采用 AAMI 标准对训练好的分类模型进行评估,每次心跳被分为 5 类心跳 N, SVEB, VEB, F 和 Q 中的一种。该标准为心电图自动分类的性能评估定义了评价指标:敏感度(Sensitivity, Sen)、正预测率(Positive predictive value, Ppv)、特异度(Specificity, Spe)和总准确率(Accuracy, Acc)。Acc 用来衡量系统的总体性能; Sen, Ppv 和 Spe 用于衡量算法对每个类别的分类表现。为了更好地衡量分类准确度,本文对 F1 指数进行了计算。

TP(True Positive), TN(True Negative), FP(False Positive)和 FN(False Negative)分别表示属于第  $i$  类真阳性、真阴性、假阳性和假阴性的数量。Sen, Ppv, Spe, Acc 和 F1 的计算公式如下:

$$Sen_i = \frac{TP_i}{TP_i + FN_i} \quad (10)$$

$$Ppv_i = \frac{TP_i}{TP_i + FP_i} \quad (11)$$

$$Spe_i = \frac{TN_i}{TN_i + FP_i} \quad (12)$$

$$Acc_i = \frac{TP_i + TN_i}{TP_i + TN_i + FP_i + FN_i} \quad (13)$$

$$F1 = \frac{2 * Sen_i * Ppv_i}{Sen_i + Ppv_i} \quad (14)$$

表 2 中比较了初始模型、本地模型以及其他 3 种算法<sup>[6,13,16]</sup>在 5 种类别上的分类性能。可以看出,经过自适应训练以后的本地模型的分类性能有很大提高,其中 SVEB 的分类性能提高最大, Sen, Ppv 和 F1 分别提高了 72.1%, 78.9% 和 77.9%; N 类、VEB 类和 F 类的 Sen 分别达到了 99.0%, 94.0% 和 83.3%。由于 Q 类的全局训练样本只有 8 个,而且在自适应训练集中没有出现,因此实验在 Q 类的识别上没有效果。从结果上来看,本文算法比其他 3 种算法的整体准确率都高,特别是 N 类和 SVEB 类的识别率明显高于其他算法; VEB 识别率较高,达到了 94.7%; F 类由于训练样本太少而识别率不高。其他算法由于使用了不同的实验数据集<sup>[9-10]</sup>,或者没有遵从 AAMI 标准建议分类<sup>[11,15]</sup>,因此不能直接与本算法相比较。

表2 算法性能的比较

Table 2 Comparison of algorithm performance

算法	Acc	N			SVEB			VEB			F			Q
		Sen	Ppv	F1	Sen	Ppv	F1	Sen	Ppv	F1	Sen	Ppv	F1	Sen/Ppv
初始模型	90.6	95.6	94.6	95.1	2.4	11.8	3.9	79.2	63.7	70.6	25.2	16.0	19.6	0
本地模型	<b>97.6</b>	99.0	98.7	<b>98.8</b>	74.5	90.7	<b>81.8</b>	94.0	95.5	94.7	83.3	46.1	59.4	0
文献[6]算法	93.9	94.3	99.4	96.8	87.7	47.0	61.2	94.3	96.2	95.2	74.0	29.1	41.8	0
文献[13]算法	97.5	99.0	98.4	98.7	71.4	94.4	81.3	93.3	93.3	93.3	82.7	58.5	68.5	0
文献[16]算法	97.4	99.8	97.6	98.7	66.9	95.7	78.8	93.0	98.2	95.5	86.9	83.3	85.1	0

(单位:%)

临床上, SVEB 和 VEB 被认为是两种关键的异常,通常通过评估 SVEB 和 VEB 的分类性能衡量分类器的表现。为了进行比较,本实验也采用与其他文献<sup>[5-8,14,16]</sup>相同的办法分

别评估了 VEB 和 SVEB 的检测性能,如表 3 所列。这些算法的分类都符合 AAMI 标准,并且也都使用了 MIT-BIH 心律失常数据库的记录进行了实验。

表3 实验结果比较

Table 3 Comparison of experiment results

算法	VEB					SVEB				
	Acc	Sen	Spe	Ppv	F1	Acc	Sen	Spe	Ppv	F1
文献[5]算法	94.8	78.9	96.8	75.8	77.3	—	—	—	—	—
文献[6]算法	96.4	77.5	98.9	90.6	83.5	92.4	76.4	93.2	38.7	51.4
文献[8]算法	97.9	90.3	98.8	92.2	91.2	96.1	81.8	98.5	63.4	71.4
文献[7]算法	98.8	94.3	99.4	95.8	95.0	97.5	74.9	98.8	78.8	76.8
文献[14]算法	98.9	95.9	99.4	96.2	96.0	96.4	68.8	99.5	79.2	73.6
本文算法	99.1	94.2	99.8	98.3	96.2	98.3	75	99.6	92.6	82.9
文献[16]算法	99.3	96.0	99.8	98.3	97.1	98.6	75.2	99.9	99.8	85.6

不同文献的分类器所使用的测试集有所不同,相关文献通常是以共同记录的测试结果来比较算法的性能。这 7 种算法共同的测试记录有 14 条,包括 200, 202, 210, 212, 213, 214, 219, 221, 222, 228, 231, 232, 233 和 234,其中 212, 222 和 232 只包含了 SVEB 类型的心拍,所以 VEB 检测是基于 200, 202, 210, 213, 214, 219, 221, 228, 231, 233 和 234 这 11 条记录进行的测试。SVEB 检测基于共有的 14 条记录进行测试。比较结果如表 3 所列。

在所有算法中, VEB 的识别率要比 SVEB 的识别率高,原因在于 SVEB 类在训练数据中的样本数较少,而且很多 SVEB 的心拍被误分为 N 类。总体来说,本文提出的算法在 VEB 和 SVEB 上的分类性能均优于除文献[16]的其他 5 种算法<sup>[5-8,14]</sup>,特别是在 SVEB 分类上, F1 指数至少高出 6.1%, 达到了 82.9%。Saadatnejad 等<sup>[16]</sup>的算法在 VEB 的分类性能上与本文算法相当,虽然其在 SVEB 分类上的 Ppv 值略高,但本文算法的计算复杂度小,对可穿戴设备的缓存配置要求

不高,能够实现对心电图的实时监测。

**结束语** 本文重点针对可穿戴设备场景下的心电图分类算法进行讨论,提出了基于双向 LSTM 的网络结构,结合可穿戴设备个体化的特点,基于自适应算法充分利用病人个体心电图的特征,对初始模型进行参数微调,优化了个体心电图的本地分类模型。然而,利用可穿戴设备进行实际监测的过程中,在数据收集处理、模型配置等方面还存在很大的挑战。同时,数据收集和模型配置也是联合多个可穿戴设备构建机器学习系统进行心电图联邦学习需要解决的首要问题。

### 参 考 文 献

- [1] HU S S,GAO R L,LIU L S,et al. Summary of China cardiovascular disease report 2018[J]. China Circulation Journal,2019,34(3):209-220. (in Chinese)  
胡盛寿,高润霖,刘力生,等.《中国心血管病报告》概要[J]. 中国循环杂志,2019,34(3):209-220.
- [2] GARG V K,DEKEL O,XIAO L. Learning SMaLL Predictors [J/OL]. <https://arxiv.org/abs/1803.02388>.
- [3] YANG T,ANDREW G,EICHNER H,et al. Applied Federated Learning:Improving Google Keyboard Query Suggestions[J]. arXiv:1812.02903v1.
- [4] HOEKEMA R,UJEN G J H,OOSTEROM A V. Geometrical aspects of the interindividual variability of multilead ECG recordings[J]. IEEE Transactions on Biomedical Engineering,2001,48(5):551-559.
- [5] HU Y H,PALREDDY S,TOMPKINS W J. A patient-adaptable ECG beat classifier using a mixture of experts approach[J]. IEEE Transactions on Biomedical Engineering,1997,44(9):891-900.
- [6] CHAZAL P D,REILLY R B. A patient-adapting heartbeat classifier using ECG morphology and heartbeat interval features[J]. IEEE Transactions on Biomedical Engineering,2006,53(12):2535-2543.
- [7] JIANG W,KONG S G. Block-Based Neural Networks for Personalized ECG Signal Classification[J]. IEEE Transactions on Neural Networks,2007,18(6):1750-1761.
- [8] INCE T,KIRANYAZ S,GABBOUJ M. A generic and robust system for automated patient-specific classification of ECG signals[J]. IEEE Transactionson Biomedical Engineering,2009,56(5):1415-1426.
- [9] RAJPURKAR P,HANNUN A Y,HAGHPANAHI M,et al. Cardiologist-level arrhythmia detection with convolutional neural networks[J]. arXiv:1707.01836v1.
- [10] HANNUN A Y,RAJPURKAR P,HAGHPANAHI M,et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network[J]. Nature Medicine,2019,25(1):65-69.
- [11] JUN T J,NGUYEN H M,KANG D,et al. Ecg arrhythmia classification using a 2-d convolutional neural network[J]. arXiv:1804.06812v1.
- [12] ACHARYA U R,OH S L,HAGIWARA Y,et al. A deep convolutional neural network model to classify heartbeats[J]. Computers in Biology and Medicine,2017,89:389-396.
- [13] LUO K,LI J Q,WANG Z G,et al. Patient-Specific Deep Architectural Model for ECG Classification[J]. Journal of Healthcare Engineering,2017,2017(1):1-13.
- [14] KIRANYAZ S,INCE T,GABBOUJ M. Real-time patient-specific ecg classification by 1-d convolutional neural networks[J]. IEEE Transactions on Biomedical Engineering,2016,63(3):664-675.
- [15] OH S L,NG E Y,TANC R S,et al. Automated diagnosis of arrhythmia using combination of CNN and LSTM techniques with variable length heart beats[J]. Computers in Biology and Medicine,2018,102(1):278-287.
- [16] SAADATNEJAD S,OVEISI M,HASHEMI M. LSTM-Based ECG Classification for Continuous Monitoring on Personal Wearable Devices[J]. IEEE Journal of Biomedical and Health Informatics,2019,2019(1):1-9.
- [17] PAN J,TOMPKINS W J. A real-time QRS detection algorithm [J]. IEEE transactions on biomedical engineering,1985,1985(3):230-236.
- [18] ANSI/AAMI/ISO EC57. Testing and reporting performance results ofcardiac rhythm and ST segment measurement algorithms [S]. Association for the Advancement of Medical Instrumentation(AAMI),2008.
- [19] CHAZAL P D,DWYER M O,REILLY R B. Automatic classification of heartbeats using ECG morphology and heartbeat interval features[J]. IEEE Transactions on Biomedical Engineering,2004,51(7):1196-1206.