

DOI: 10.13382/j.jemi.2017.12.005

基于深度学习的运动心率测量系统*

荣凡稳 郑伟 陈冉 高军峰

(中南民族大学 生物医学工程学院 认知科学国家民委重点实验室 武汉 430074)

摘要:针对当前动态心率测量方法中存在心率监测准确度不高的缺点,提出使用深度学习算法提取光电容积脉搏波(photo-plethysmograph, PPG)中的心率值。方法采集了15名身体健康的受试者不同运动速度下的PPG信号,并通过有抗干扰能力的心电(electrocardiogram, ECG)设备同步采集他们的ECG信号,将具有较强干扰的PPG信号作为堆栈自编码(stacked auto-encoder, SAE)网络的输入信号,并将ECG信号作为网络标签,然后使用深度学习算法对自编码网络进行训练,以将有较强干扰PPG信号拟合为具有准确心率特征的类正弦波信号,从而实现对运动状态下干扰严重的PPG信号进行心率的提取。将SAE网络输出信号与对应ECG信号进行比较,结果显示,运动心率测量的平均误差为1.1658 bpm,表明深度学习算法对于心率测量的有效性,也为运动心率信号测量提供了一种新的途径。

关键词:运动心率测量;深度学习;脉搏;堆栈自编码网络

中图分类号: TN29; R318.6 **文献标识码:** A **国家标准学科分类代码:** 310.6110

Sportive heart rate measuring system based on deep learning

Rong Fanwen Zheng Wei Chen Ran Gao Junfeng

(Biomedical Engineering College, South-Central University for Nationalities, Wuhan 430074, China)

Abstract: The main disadvantage of current methods of dynamic heart rate measurement is the low accuracy. In order to improve the problem, deep learning algorithm was introduced to extract the photoplethysmograph (PPG) of heart rate value. In this paper, the pulse signals of 15 healthy subjects participated in the experiment was acquired under the different velocity as the input of stacked auto-encoders network (SAE). At the same time, electrocardiograph (ECG) signal as the label of that network was gathered by a standard ECG collector which has high anti-interference. Combining with the deep learning algorithm, SAE was trained, in which the pulse signal with strong interference was fitted to the signal of sine-like wave with the characteristic of accurate heart rate, in order to realize the extraction of heart rate under the condition of serious disturbance under sports conditions. The experimental results show that compared with the output signal of SAE, the proposed method obtains smaller error value of the heart rate (1.1658 bpm), which shows the effectiveness of heart rate measurement using deep learning algorithm, and provides a new way for the sportive heart rate measurement.

Keywords: sportive heart rate measurement; deep learning; pulse; stack auto-encoders network

0 引言

心率是一项重要的生命体征,是评估身体状况最直接有效的指标之一。在人体血容量和代谢等状态基本不变的情况下,心率的改变直接反应了心脏的功能状态,可

以反应出各种状态下心脏的工作情况^[1],研究表明静息心率过快更容易引发心血管疾病^[2],另外,由于运动状态下,容易引起心率变化,出现心脏异常工作的情况,心率对运动状况的评估也具有重要的作用^[3]。因此心率监测对疾病防治与运动健康具有十分重要的意义。

通常情况下采集脉搏信号容易受到人体活动和外界

的干扰,难以准确的获取动态心率信息。心率测量设备常因噪声严重导致设备的测量值存在误差较大及错误预警等问题。现有一些方案用于改善心率的估计,2015 年周聪聪等人^[4]在研究双通道脉搏传感器时根据人体腕部生理解剖特点,提出桡动脉、尺动脉双通道脉搏及差分信号同步检测的方法,通过实验验证了该检测方法对轻微运动具有一定的抗干扰能力,但心率检测模块尺寸过大且无法在跑步等运动状态下对心率做出准确的估计。徐礼胜等人^[5]对多传感器融合的方法进行研究时,分别融合 ECG 和脉搏波信号获取融合心率,相比单一从 ECG 或脉搏信号所得心率,融合心率准确度提高 46% 以上,但该方法可穿戴性不强且仅在禁止和正常运动幅度之内才能有效避免干扰。张家盛等人^[6]研究使用自适应滤波器时,用三轴加速度计获取噪声源构建自适应滤波器来消除设备运动干扰,可用于日常健康维护,但运动状态的测量精度还需要进一步的改进。2016 年黄驰等人^[7]在研究非接触式心率监测时,通过分析人脸的血液和组织反射光的光强变化,得出这些光成分的周期性变化,定量的得到脉搏的周期性信号变化,此方法准确性受滤波算法和摄像头帧率影响较大。可见,要想在运动状态下提供可靠的心率监测,目前的方案难以实现。

机器学习在人工智能领域具有重要的地位,如果一个系统不具有学习能力,那么这个系统就不是一个真正的智能系统^[8]。深度学习是机器学习的一个分支,其概念由 Hinton 等人^[9]于 2006 年提出,指基于样本数据通过一定的训练方法得到包含多个层级的深度网络结构的机器学习过程^[10]。深度学习主要特点是通过多层次的学习而得到对于原始数据不同抽象程度的表示,进而提高分类和预测等任务的准确性。近年来,随着对深度学习的不断研究,该方法在数字广播^[11]、语音识别^[12]、图像处理^[13-15]和故障检测与辨识^[16]等多类应用中取得了突破性进展。

由于运动状态下脉搏信号受到的干扰严重,传统的自适应滤波、卡尔曼滤波等方法效果有限,导致目前在运动状态下对心率信号采集不满意,误差仍然较高。基于深度学习方法在其他相关领域的成功应用,本文提出使用深度学习算法提取动态光电容积脉搏波 (photoplethysmograph, PPG) 信号中的心率值的方法,使用光电传感器采集腕部 PPG 信号,采用 6 轴传感器采集运动状态信号,并通过心电监护系统采集心电 (electrocardiogram, ECG) 信号,采用逐层贪婪训练法对采集信号进行训练。结果表明通过深度学习训练的方式能有效降低干扰对心率估计的影响,能够在运动状态下获取较为准确的心率,因而为制造一种准确测量心率信号的可穿戴设备提供了一种新的途径。

1 信号采集与处理

1.1 受试者

本文选取本校 15 名身体健康(无任何心脏相关的疾病及运动障碍,男女分别 7 名及 8 名)的本科生作为受试者,平均年龄 21.3 岁。分别采集受试者静态、行走和跑步 3 种状态下的 PPG 信号与 ECG 信号作为深度学习网络训练数据。

1.2 PPG 信号采集

对于脉搏信号,本文没有在指端或耳垂处使用光电传感器采集,这两种传感器使用起来不是很方便,而且容易影响到日常生活,在运动时则更为麻烦。为了设备佩戴美观并提高系统可靠性,使用反射式光电容积法的 SON1303 传感器采集腕部脉搏波。从传感器发出的光除被腕部组织吸收以外,一部分由血液漫反射返回,并经由光电转换器转变为电信号,然后通过放大器放大输出。由于动脉血管是随着心脏周期性变化,因此光电转换器输出的电信号变化周期就是心率。

本文使用低功耗、低漂移、高共模抑制比的运算放大器 SON3130 对信号进行放大。选择低功率单片机 STM32F103C8T6 片内 10 位高分辨率的 ADC 模块对 SON3130 放大后的信号进行采样,采样率设置为 300 Hz,再由串口通过蓝牙发送到电脑平台。

1.3 ECG 信号采集

通过堆栈自编码 (stacked auto-encoder, SAE) 训练多个隐层,对神经网络进行微调时,需要找到能够作为神经网络微调的标签,因此需要采集与 PPG 同步的 ECG 信号,经过处理后作为神经网络训练标签。

本文使用了一款精度高、抗干扰能力强的心电设备 (设备型号:XD-2000B;设备厂家:宁波市美灵思医疗科技有限公司) 来采集 II 导联的 ECG 信号,采样率为 300 Hz。此外,由于 PPG 信号与 ECG 信号的起始位置需要确定,因此使用空闲的 V1 导联记录标记位置。

1.4 数据预处理

ECG 信号中包含了大量的细节信息,本文只需要 R 峰的位置信息即可,因此通过小波算法提取 ECG 的 R 峰的位置,为了降低训练难度,把 ECG 整合成类正弦波以作为神经网络的标签。如图 1 使用小波算法标记 ECG 信号 R 峰。

将每名受试者采集的连续 PPG 及对应的 ECG 信号均分割为 3 s 的数据段,考虑到大量的样本进行训练耗时耗力,本研究对原始 PPG 信号和 ECG 信号进行降维处理,采取隔 2 个点降采样的方法,把每秒的数据降为 100 个点,作为最终的 SAE 网络的输入信号及标签。

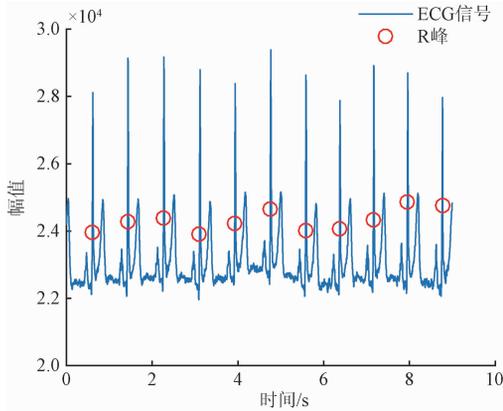


图1 标记R峰的ECG信号

Fig.1 ECG signal with the mark R peak

2 深度学习堆栈自编码

2.1 深度学习

深度学习^[10]是指基于样本数据通过一定的训练方法得到包含多个层级的深度网络结构的机器学习过程。深度神经网络是由多个单层神经网络构成的,常见的单层神经网络按照编码情况分为3类:只包含编码器部分、只包含解码器部分、编码器提供从输入到隐含特征空间的自底向上的映射,解码器以重建结果尽可能接近原始输入为目标将隐含特征映射输入空间^[17]。深度神经网络分为以下3类:1)前馈深度网络,由多个编码器层叠加而成;2)反馈深度网络,由多个解码器层叠加而成;3)双向深度网络,通过叠加多个编码器层和解码器层构成。

深度学习和传统的浅层学习区别在于,深度学习在构建网络模型的时候包含多个隐含层,一般包含3~10个隐含层。隐含层的节点可以比输入层少,这样迫使网络学习到更加有效的特征,也可以比输入层多,这就相当于把信号转换到了一个新的坐标空间表示,这样会让最终的拟合和分类更加的准确。

2.2 SAE

自编码是20世纪末期提出来的^[9,18]。自编码包含了3层网络,即单个输入层、单个隐藏层和单个输出层,这里的输入层和输出层有着相同的节点数。

如果在自编码的基础上加上L1正则化,那么该正则化将会约束各个隐层大部分节点为0。只有少数节点不为0。由此人们把这种编码方式命名为稀疏自编码。这种方式是模拟人的大脑神经元,当人的大脑处理信息的时候只有少部分神经元被激活,大部分神经元处于抑制状态。也就是让隐层各个节点中接近1的特征点尽量少。这个就是对隐层的稀疏性限制。稀疏的表达方式往

往比其他的表达训练的效果更为显著。

栈式自编码神经网络是把稀疏自编码网络堆叠起来,其前一层稀疏自编码器的输出特征作为其后一层自编码器的输入。进行无监督的逐层训练。每一层都可以看成一层稀疏自编码,当该层能够重构上一层,重构误差最小的时候,就可以训练下一层。当完成每一个隐层的训练的时候,下一步进行有监督的微调,在SAE最后一个隐层添加逻辑回归层,进行有目标的训练,从而训练出深度学习的整个网络。为了得到更好的结果,固定每层的某些参数采用反向传播算法进行全局微调。为了防止出现局部最优,只有到函数快收敛的时候才进行微调。

现假设一份有标签的训练集共有 m 个样本 $\{(x^{(1)}, y^{(1)}), \dots, (x^{(m)}, y^{(m)})\}$ 。 \mathbf{x} 为输入参数, y 为 \mathbf{x} 的标签。SAE从前向后逐层训练每层网络,方法为:

$$\mathbf{z}^{(l+1)} = \mathbf{W}^{(l)} \mathbf{a}^{(l)} + \mathbf{b}^{(l)} \quad (1)$$

$$\mathbf{a}^{(l+1)} = f(\mathbf{z}^{(l+1)}) \quad (2)$$

式中: $\mathbf{a}^{(l)}$ 表示第 l 层的激活值(输出值),当 $l=1$ 时, $\mathbf{a}^{(l)} = \mathbf{x}$; $\mathbf{b}^{(l)}$ 是第 $l+1$ 层的偏置项; $\mathbf{w}^{(l)}$ 为第 l 层与第 $l+1$ 层之间的权值矩阵; f 为激活函数; $\mathbf{z}^{(l+1)}$ 为第 $l+1$ 层输入加权和,上述计算过程即为前向传播。假设 $h_{w,b}(\mathbf{x})$ 为最终输出,那么该网络的损失函数即为:

$$J(\mathbf{W}, \mathbf{b}; \mathbf{x}, \mathbf{y}) = \frac{1}{2} \|\mathbf{h}_{w,b}(\mathbf{x}) - \mathbf{y}\|^2 \quad (3)$$

加入正则化项(权重衰减项),防止过拟合。如下:

$$J(\mathbf{W}, \mathbf{b}) = \left[\frac{1}{m} \sum_{i=1}^m \left(\frac{1}{2} \|\mathbf{h}_{w,b}(\mathbf{x}^{(i)}) - \mathbf{y}^{(i)}\|^2 \right) \right] + \frac{\lambda}{2} \sum_{l=1}^{n-1} \sum_{i=1}^{s_l} \sum_{j=1}^{s_{l+1}} (\mathbf{W}_{ij}^{(l)})^2 \quad (4)$$

式中: n 为网络层数, s_l 表示第 l 层的神经元个数, λ 表示正则化系数。式(4)的第1项为均方差项,第2项为规则化项,用于减小权重的幅度,防止过度拟合。

本文用随机梯度下降找到上式的最小损失值,对于每一次梯度下降迭代可得下列表达式:

$$\mathbf{W}_{ij}^{(l)} = \mathbf{W}_{ij}^{(l)} - \alpha \frac{\partial}{\partial \mathbf{W}_{ij}^{(l)}} J(\mathbf{W}, \mathbf{b}) \quad (5)$$

$$b_i^{(l)} = b_i^{(l)} - \alpha \frac{\partial}{\partial b_i^{(l)}} J(\mathbf{W}, \mathbf{b}) \quad (6)$$

式中: α 是学习速率。梯度下降每次迭代都会更新 \mathbf{W} 和 \mathbf{b} 。多次迭代得出损失函数的最小值。

通过前向传播算法计算每层神经元的特征值,包括输出 $h_{w,b}(\mathbf{x})$,然后通过反向传播算法获得函数 $J(\mathbf{W}, \mathbf{b})$ 偏导数,对每层神经元的特征值进行调整。这里定义 $\delta_i^{(n)}$ 为输出层的第 i 个节点对最终输出残差的贡献值,称为残差。若输出为 a_i^n ,那么:

$$\delta_i^{(n)} = \frac{\partial}{\partial z_i^{(n)}} \frac{1}{2} \|\mathbf{y} - \mathbf{h}_{w,b}(\mathbf{x})\|^2 = - (y_i - a_i^{(n)}) \cdot f'(z_i^{(n)}) \quad (7)$$

根据式(7)用链式法则可以得到:

$$\delta_i^{(l)} = \left(\sum_{j=1}^{s_{l+1}} W_{ji}^{(l)} \delta_j^{(l+1)} \right) f'(z_i^{(l)}) \quad (8)$$

式(8)表示为用反向算法调整最终的总残差和权值矩阵。

将隐层进行稀疏表达。让每个节点的平均激活值较小。现在定义 $\hat{\rho}_j$ 为隐层节点 j 的平均激活量。在 m 个样本的平均激活量的具体表达式为:

$$\hat{\rho}_j = \frac{1}{m} \sum_{i=1}^m [a_j^{(2)}(x^{(i)})] \quad (9)$$

这里期望 $\hat{\rho}_j$ 的稀疏度非常小,接近于 0(一般为 0.05)大多数隐层节点变成非激活的状态。本研究两层传递的方式为用 sigmoid 函数进行拟合,拟合结果表现为节点的大多数数值接近于 0。

设本文所以期望的平均激活量为 ρ 。实际激活量为 $\hat{\rho}_j$ 。为了让 $\hat{\rho}_j$ 无限接近于 ρ ,这里引入 KL 散度来对偏离 ρ 的 $\hat{\rho}_j$ 进行惩罚,具体表达式如下:

$$KL(\rho \parallel \hat{\rho}_j) = \rho \log \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_j} \quad (10)$$

最终损失函数的形式表达式为:

$$J_{\text{sparse}}(\mathbf{W}, \mathbf{b}) = J(\mathbf{W}, \mathbf{b}) + \beta \sum_{j=1}^{s_2} KL(\rho \parallel \hat{\rho}_j) \quad (11)$$

其中 $J(\mathbf{W}, \mathbf{b})$ 参考式(3), β 为 KL 散度的加权系数。

本研究中把隐层节点平均激活程度 ρ 设置为 0.05,那么偏离 ρ 越远,散度就会越大,惩罚系数也随之增大。

上述即为建立稀疏自编码网络的过程,SAE 就是包含了多个稀疏自编码。本文假设一个包含两个隐层的 SAE。训练第 1 个稀疏自编码器,能够训练到第 1 层的原始特征值。然后把学习的第 1 层稀疏的特征作为下一层稀疏自编码的输入,进行第 2 层稀疏自编码,得到第 2 层的特征。接下来再把第 2 层的特作为最后一层拟合层的输入。训练的到一个能够很好拟合脉搏波形的网络。最后把上面的网络组合起来,包含了一个输入层,两个隐层,一个输出层。

本文使用 10 折交叉验证,在训练完成后将测试数据的 PPG 信号,送入训练后的神经网络计算出心率,然后与对应的测试数据 ECG 信号的心率值做对比,计算两者间的差值,计称为系统误差,最终,计算 10 次系统误差的平均值作为对测量系统的心率测量系统的准确度的评价指标。

3 实验结果

将 PPG 信号作为输入,整合后的 ECG 信号(类正弦波)作为标签,对上述 SAE 网络进行学习训练。网络结构中,本文采用 2 个隐层,并在最后一个隐层的基础上加上一个神经网络,用做最后数据的拟合输出。

用于训练的数据量为 20 000 个样本,每个样本 300 个数据点,确保每个样本包含一个完整的 PPG 信号。第 1 个隐层结点数为 90,稀疏度设置为 0.05,即每个隐藏单元的平均激活值接近 0.05。第 2 个隐藏层结点数为 60,稀疏度设置为 0.05。第 3 个隐层结点数为 30,稀疏度设置为 0.05。

原始数据中加入随机噪声以防止过度拟合,图 2 所示为加入随机噪声的原始信号及通过 SAE 的第一次训练、重构的结果。可以看出重构出来的结果基本可以还原出 PPG 信号的特征。

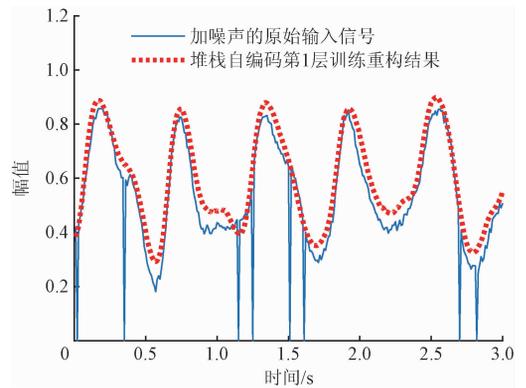


图 2 SAE 第 1 层重构训练结果

Fig. 2 The first layer reconstruction training results of SAE

为了避免由参数优化过大导致过拟合,本文使用正则化对参数优化进行约束。如果正则化的系数设置过大,权值 \mathbf{W} 的惩罚力度也会相应加大,最终的拟合没有任何流向。因此需要选择合适正则化参数 λ 。根据多次调试,正则化参数 λ 设置为 0.000 1。

训练结束后,使用测试 PPG 数据送入 SAE 以输出含有心率信息的数据。在参数设置不恰当的情况下,可能会出现局部最优。为此使用 10 折交叉验证,将 10 次系统误差测试值平均作为系统的评价指标,以此避免局部最优结果对系统效率的客观评估。

采用 SAE 训练 PPG 信号,最后用神经网络微调,图 3 列出了运动状态下的测试结果,可以看出在输入 PPG 信号存在严重干扰的情况下,通过 SAE 网络仍然可以拟合出与标签类相似的输出信号,以获取准确的心率。

由图 3 可以看出,在运动状态下 PPG 波形已经出现严重干扰的情况下,也能通过神经网络得到比较理想的输出。选取从行走、跑步到静息的一组数据,通过小波算法提取深度学习网络输出和 ECG 信号的心率,将它们对比如图 4 所示。

由图 4 可以看出,在走动状态和静息状态下,神经网络训练再测试后得到的输出数据的心率与对应 ECG 信号的心率值基本相同;在跑动状态下会有个别偏差,分析

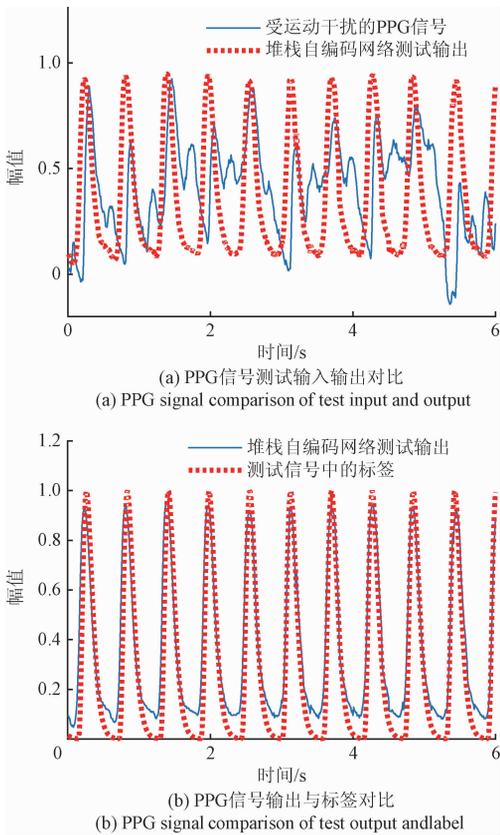


图3 运动情况下的训练结果

Fig.3 Training results under movement state

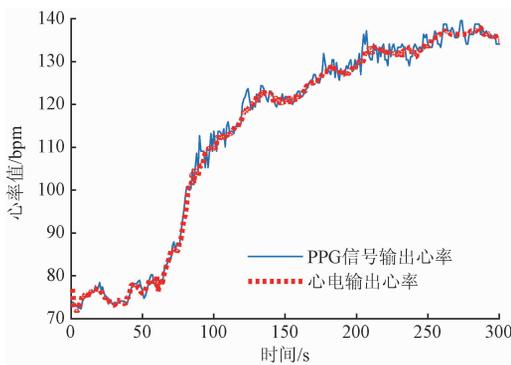


图4 测试心率及心电图结果对比

Fig.4 The results comparison of the test heart rate and the ECG heart rate

原因,这是由于原始 PPG 信号干扰过于严重导致。

本文将心电采集的心电用小波算法提取出心率 HR_{ECC} 作为估计心率。把 HR_{ECC} 作为参照计算堆栈自编码网络的训练结果的误差。把两者的平均误差 \bar{u} 和均方误差 s 计为 $\bar{u} \pm s$ 。表1 总结 10 折交叉验证输出结果,此时运动心率测量的平均误差为 1.165 8 bpm。相比于其他动态心率采集方式(如多传感器融合^[5]的运动心率估计

误差达到了 -16.542 ± 202.691 4),本文提出的算法测试误差小。

表1 运动状态下心率估计误差

Table 1 Heart rate estimation error under movement state

10 折交叉验证	$\bar{u} \pm s/\text{bpm}$
交叉验证 1	-1.8149 ± 6.4424
交叉验证 2	0.0100 ± 0.9000
交叉验证 3	-1.3094 ± 8.6300
交叉验证 4	2.5858 ± 15.1535
交叉验证 5	1.3093 ± 19.1854
交叉验证 6	0.4327 ± 21.9141
交叉验证 7	-2.0577 ± 2.0543
交叉验证 8	1.6393 ± 14.1705
交叉验证 9	0.0100 ± 0.8958
交叉验证 10	0.4890 ± 8.7907

4 结论

本文通过反射式光电传感器采集腕部 PPG 信号作为训练数据,用抗干扰的心电监护仪采集 ECG 信号制作训练标签,通过深度学习中的 SAE 算法来对 PPG 信号中的心率的提取。利用 SAE 逐层贪婪训练算法进行训练,以此获取栈式自编码神经网络参数。然后使用测试 PPG 数据送入网络,获得具有 PPG 信号特征的输出信号,以此获得准确的心率数据。经测试,此方案将心率获取误差控制在 ± 5 以内。因此,将深度学习算法应用于 PPG 信号中的心率提取,相比传统方法,可得到更小的系统误差,因而在健康监护与合理运动方面提供了一个可行方案。另外,本研究中用于训练的受试者数量及年龄阶段有限,后期研究可以进一步加大受试者数量,扩大年龄阶段,以使得设备具有更高的测量精度及更广的适用性。

参考文献

[1] 吴学思. 心率在心血管疾病中的意义[J]. 中华内科杂志, 2006, 45(7):601-602.
WU X S. The significance of heart rate in cardiovascular disease[J]. Chinese Journal of Internal Medicine, 2006, 45(7):601-602.

[2] FERNANDES R A, VAZRONQUE E R, VENTURINI D, et al. Resting heart rate: Its correlations and potential for screening metabolic dysfunctions in adolescents[J]. BMC Pediatrics, 2013, 13(1):1-7.

[3] PARADISO M, PIETROSANTI S, SCALZI S, et al. Experimental heart rate regulation in cycle-ergometer exercises [J]. IEEE Transactions on Biomedical Engineering, 2013, 60(1):135.

[4] 周聪聪, 涂春龙, 高云, 等. 腕戴式低功耗无线心率监测装置的研制[J]. 浙江大学学报(工学版), 2015, 49(4):798-805.

- ZHOU C C, TU C L, GAO Y, et al. Low power, wireless, wrist-worn device for HR monitoring based on double channels of pulse sensing[J]. Journal of Zhejiang University (Engineering Science), 2015, 49 (4): 798-805.
- [5] 徐礼胜, 靳雁冰, 王琦文, 等. 多传感器融合的穿戴式心率监测系统[J]. 哈尔滨工业大学学报, 2015, 47(5):97-103.
XU L SH, JIN Y B, WANG Q W, et al. Multi-sensor fusion for wearable heart rate monitoring system [J]. Journal of Harbin Institute of Technology, 2015, 47(5): 97-103.
- [6] 张家盛, 张加岭, 禹东川, 等. 可穿戴式心率检测系统的设计[J]. 自动化与仪器仪表, 2015(2):107-108.
ZHANG J SH, ZHANG J L, YU D CH, et al. The design of the wearable heart rate detection system [J]. Automation and Instrumentation, 2015(2):107-108.
- [7] 黄驰, 黄伟源, 龚志敏, 等. 基于 MATLAB 的非接触式心率测量[J]. 科学家, 2016, 4(7):18-19.
HUANG CH, HUANG Y W, GONG ZH M, et al. Non-contact heart rate measurement based on MATLAB [J]. Scientist, 2016, 4(7):18-19.
- [8] 刘建伟, 刘媛, 罗雄麟. 深度学习研究进展[J]. 计算机应用研究, 2014, 31(7):1921-1930.
LIU J W, LIU Y, LUO X L. Research and development on deep learning [J]. Application Research of Computers, 2014, 31(7):1921-1930.
- [9] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets [J]. Neural Computation, 2006, 18(7):1527.
- [10] 尹宝才, 王文通, 王立春. 深度学习研究综述[J]. 北京工业大学学报, 2015(1):48-59.
YING B C, WANG W T, WANG L CH. Review of deep learning [J]. Journal of Beijing University of Technology, 2015(1):48-59.
- [11] 范文斯路, 吴乐南. 复合调制 AM 广播接收机的 DL-SAE 码元判决法 [J]. 电子测量与仪器学报, 2016, 30(10):1490-1496.
FAN W S L, WU L N. Deep learning-sparse autoencoder for symbol discrimination in composite AM broadcasting receiver [J]. Journal of Electronic Measurement and Instrumentation, 2016, 30(10):1490-1496.
- [12] ZE H, SENIOR A, SCHUSTER M. Statistical parametric speech synthesis using deep neural networks [C]. IEEE International Conference on Acoustics, Speech and Signal Processing, 2013:7962-7966.
- [13] ZEILER M D, FERGUS R. Visualizing and understanding convolutional networks [C]. Computer Vision and Pattern Recognition, 2013:818-833.
- [14] 张春雨, 韩立新, 徐守晶. 基于栈式自动编码的图像哈希算法[J]. 电子测量技术, 2016, 39(3):46-49.
ZHANG CH Y, HAN L X, XU SH J. Image Hashing algorithm based on stacked autoencoder [J]. Electronic Measurement Technology, 2016, 39(3):46-49.
- [15] 曲景影, 孙显, 高鑫. 基于 CNN 模型的高分辨率遥感图像目标识别[J]. 国外电子测量技术, 2016, 35(8):45-50.
QU J Y, SUN X, GAO X. Remote sensing image target recognition based on CNN [J]. Foreign Electronic Measurement Technology, 2016, 35(8):45-50.
- [16] 王培良, 夏春江. 基于 PCA-PDBNs 的故障检测与自主学习辨识 [J]. 仪器仪表学报, 2015, 36 (5): 1147-1154.
WANG P L, XIA CH J. Fault detection and self-learning identification based on PCA-PDBNs [J]. Chinese Journal of Scientific Instrument, 2015, 36(5):1147-1154.
- [17] ZEILER M D, KRISHNAN D, TAYLOR G W, et al. Deconvolutional networks [C]. Computer Vision and Pattern Recognition. IEEE, 2010:2528-2535.
- [18] 徐世彬. 家庭式心电检测系统研究及实现 [D]. 西安:西安科技大学, 2006.
XU SH B. Research and realization of domestic ECG detecting system [D]. Xi'an: Xi'an University of Science and Technology, 2006.

作者简介



荣凡稳, 1991 年出生, 2015 年于武汉工商学院获得学士学位, 现为中南民族大学硕士研究生, 研究方向生物医学工程智能仪器开发。

E-mail: 18064061506@163.com

Rong Fanwen was born in 1991, and received B. Sc. from Wuhan Technology and Business University in 2015. And he is a M. Sc. candidate in South-Central University for Nationalities now. His present research interest includes intelligent instrument development of biomedical engineering.



郑伟, 1992 年出生, 2015 年于中南民族大学获得硕士学位, 现为中南民族大学硕士研究生, 研究方向生物医学工程模式识别。

Zheng Wei was born in 1992, and received B. Sc. from South-Central University for Nationalities in 2015. And he is a M. Sc. candidate in South-Central University for

Nationalities now. His present research interest includes pattern recognition of biomedical engineering.



高军峰, 1973 年出生, 博士, 副教授, 硕士生导师, 2005 年于武汉理工大学获得硕士学位, 2011 年于西安交通大学获得博士学位。现为中南民族大学教师, 主要从事脑电信号处理与模式识别方面的研究。

E-mail: junfengmst@163.com

Gao Junfeng was born in 1973, and received M. Sc. from Wuhan University of Technology in 2005 and Ph. D. from Xi'an Jiaotong University in 2011, respectively. He is an associate professor and M. Sc. tutor in South-Central University for Nationalities now. His present research interests include EEG signal research and pattern recognition.