

DOI: 10.19650/j.cnki.cjsi.J1904806

基于弱监督学习卷积神经网络的心脏按压评估*

鲍宇^{1,2}, 殷佳豪¹, 刘世杰¹, 杨轩¹, 朱紫维¹

(1 中国矿业大学计算机学院 徐州 221116; 2. 矿山数字化教育部工程中心 徐州 221116)

摘要:传统的基于加速度波形积分的心脏胸外按压评估方法受噪声和积分时延影响,在计算距离时存在较大误差,评估效果不理想。为此,在弱监督学习策略与波形分割的基础上,提出了一种基于一维卷积神经网络的心脏按压加速度波形识别算法,实验结果表明,一维卷积神经网络达到了99.4%的正确率,明显优于传统的积分方法和BP神经网络算法。进一步采用Grad-CAM方法对评估结果进行可视化分析,发现卷积神经网络所关注的特征集中于开始按压至按压到达平衡位置,以及此次按压松手后反向加速度达到最大值至下一次按压开始这2个阶段的加速度波形变化情况。此外该评估模型不再需要对按压距离进行精确测距,因而不受按压遮挡、电磁波干扰等因素的影响,可以实时检测按压是否规范有效,在复杂环境中也具有较高的鲁棒性,在医疗急救领域中具有一定的实用价值。

关键词:加速度波形评估;一维卷积神经网络;脉冲识别与波形分割;弱监督学习策略;一维Grad-CAM可视化

中图分类号: TP306 TH825 **文献标识码:** A **国家标准学科分类代码:** 520.2060

Assessment of chest cardiac compression in convolutional neural network based on weak supervised learning strategy

Bao Yu^{1,2}, Yin Jiahao¹, Liu Shijie¹, Yang Xuan¹, Zhu Ziwei¹

(1. College of Computer Science and Technology, China University of Mining and Technology, Xuzhou 221116, China;

2. Mine Digitization Engineering Research Center of Ministry of Education of the People's Republic of China, Xuzhou 221116, China)

Abstract: The traditional evaluation method of cardiac chest compression is based on acceleration waveform integration, which is affected by noise and integral delay. A large error is introduced in calculating the distance and the evaluation effectiveness is not ideal. Therefore, based on the weak supervised learning strategy and waveform segmentation, this paper proposes one kind of acceleration waveform recognition algorithm for cardiac chest compression based on one-dimensional convolutional neural network. Experimental results show that the one-dimensional convolutional neural network achieves 99.4% accuracy, which is significantly better than the traditional integration method and BP neural network algorithm. Further, the Grad-CAM method is adopted to visually analyze the evaluation results. The features of convolutional neural network focus on the acceleration waveform changes in the two compression stages of starting to press until the pressure can reach the equilibrium position. The reverse acceleration can achieve the maximum value after the pressing of the hand to the next press start. In addition, the evaluation model does not need to accurately measure the pressing distance. Thus, it is not affected by factors such as pressing occlusion and electromagnetic wave interference. Its effectiveness can be checked in the real-time manner. It also has the feature of high robustness in complex environment and has certain practical value in the field of medical emergency.

Keywords: acceleration waveform evaluation; one-dimensional convolutional neural network; pulse recognition and waveform segmentation; weak supervised learning strategies; one-dimensional Grad-CAM visualization

0 引言

心脏胸外按压是典型的规律性往复运动,在急救中,对于按压深度有着较精确的要求,其精度要求达到毫米级,普通的超声波测距传感器、激光传感器等测距仪器容易受按压遮挡、抖动等因素的影响,不能很好地满足精确测距的要求,而正规医疗场合使用的心肺复苏机等医疗设备虽然能精确地记录每次按压的距离,但其价格昂贵、不易于携带,因而在正规医疗场合以外难以适用。心脏骤停属于突发事件,极有可能在医院以外发生且没有时间将患者送至医院抢救,需要就地进行心脏胸外按压。在没有专用测距设备时,仅凭施救人员的经验进行急救很难判断当前进行的胸外按压是否规范有效。

一种可行的方法是利用加速度传感器代替超声波测距传感器,通过加速度二次积分得到距离,从而判断按压是否规范有效,如 Boussen 等^[1]使用惯性导航算法和加速度计监测胸部按压深度,以及钱绍文等^[2]提出的加速度二次积分测量胸外按压深度的方法。使用加速度传感器不受按压遮挡、抖动等因素的影响,而且价格低廉、体积较小、便于携带,但在实际应用中,考虑到噪声和积分时延的影响,上述方法存在着积分漂移、误差累积等问题^[3]。


观察前期研究的实验数据发现,当物体有规律地往复运动时,会产生有规律的加速度波形。心脏胸外按压规范有效时,波形相似度较高;按压距离差距超过 5 mm 时,其波形与标准波形具有明显差异;按压时出现较大抖动或按压间歇过长时,其波形与标准波形也存在明显差异^[4],说明波形信号的识别分类过程具有可学习的特征,可以利用人工智能方法进行学习并分类,从而评估心脏胸外按压的有效性。

根据上述分析,本文尝试利用卷积神经网络学习加速度波形信号的特征,避免二次积分漂移等误差。对于训练所需的大量标签数据,本文采用人工按压模拟在非医院环境下的胸外按压急救,并测量按压距离用以评估按压效果,从而得到数据标签。人工按压过程中难免因遮挡、抖动等问题造成部分数据标签的缺失,因此本文提出一种基于加权方差的弱监督学习策略,对实验数据标签进行修正;修正后建立卷积神经网络的加速度波形识别分类模型,对急救中心心脏胸外按压的波形进行评估。采用此方法不再需要进行精确测距,只需将实时采集到的加速度值输入卷积网络模型便可以实时评估本次按压是否规范有效。


1 实验平台与数据采集

为得到心脏胸外按压加速度波形数据,本文设计一个按压仿真系统来采集按压过程中的加速度数据。如图 1

(a)所示,整个按压数据采集系统可分为 3 部分:按压设备、核心控制模块和传感器模块。按压设备模拟心脏外压过程产生不同的按压波形;核心控制模块对整个系统进行控制和数据分析,并且存储至 SD 卡;传感器模块负责信息采集,对按压的加速度进行采样处理。传感器采用支持所有频率的低功耗三轴加速度计 ADXL345 和所提供的三轴加速传感器 MMA7361,可应用到多种场景,可选灵敏度在 $\pm 1.5g/6g$ 之间,内部低通滤波器具有信号调理功能^[5]。



(a) 按压数据采集系统设计
(a) Design diagram of pressure data acquisition system



(b) 胸外按压模拟实验平台
(b) Simulation experiment platform for chest compression

图 1 实验数据采集系统

Fig.1 Experimental data acquisition system

本文的采样模型分析按压时间、强度和距离。单次向下按压时间测算为 200~400 ms,则单次按压往返时间在 600~1 000 ms,采样频率设计为 100~500 Hz,按压力度范围在 0.5g~2.5g,按压标准距离为 5~6 cm,共进行 18 次数据采集,因而得到 18 组加速度变化数据,每组 50 余次按压。

2 数据预处理

每组数据都是连续按压过程中按时间点采集的加速度变化曲线,受电磁干扰影响,原始数据中含有大量白噪声,需要进行滤波处理。每组实验包含多次按压的多个脉冲,需要从原始波形中找到由按压导致的脉冲,消除干扰,并分割波形进行得到每次按压对应的加速度波形。按图 2 所示的流程进行去噪滤波、脉冲识别、波形分割与拟合等工作。




图2 数据预处理过程

Fig.2 Data preprocessing

2.1 去噪滤波处理

如图3(a)所示,从实验设备直接采集的数据含有大




图3 去噪滤波处理前后的对比

Fig.3 Comparison before and after denoising and filtering

2.2 按压脉冲识别与波形切割

由图3(b)可知,一组数据中存在多次按压,需要对加速度曲线进行按压脉冲的识别与分割。本文检查梯度特征和振幅特征进行脉冲的识别,并采用滑动窗口模型进行波形分割,区分出每一次按压脉冲的波形。

1) 滑动窗口 A 存放采样值,建立滑动窗口 B,存放过滤结果。

2) 对窗口 B 和窗口 A 进行突变阈值检测,在静止重力值出现 21% 的变化时,断定为突变阈值。

3) 对窗口 B 幅宽进行切割,从检测到的 B 突变和 A 突变点所间隔的区域中选取优化点作为起点,以单个脉冲终止点为终点,该点为脉冲突变下降沿回至标准值位置,即按压至最低点时加速度计归 0。

4) 根据窗口 B 的结果,切割滑动窗口 A。

脉冲识别算法如下。

(1) 幅宽 PW 的判断

脉冲幅宽应满足下列公式:

量白噪声和毛刺,若不进行处理将严重干扰对按压数据的分析。经测试,单维卡尔曼滤波^[6]虽然效果较好,但运算时间和复杂度较高、运算延迟较高,在损失不大的情况下,本文使用中值滤波和低通幅滤波。

在进行波形分析前使用低通幅滤波过滤白噪声和锤击异常。白噪声是一种普遍存在的环境干扰,呈现正态分布且频谱为恒值,两脉冲之间的相关性较小^[7]。如图3(b)所示,经过低通滤波后,相邻采样点间存在明显的相关性,滤波带宽越窄相关性越强;随后使用中值滤波,选取适当宽度进行过滤,采用尾端判断、头端删除法处理数据,将连续采样得到的数据存放在数组中,每得到新的数据即追加在数组的尾部,同时将数据依次向前移动,删除原数组的首位数据,将剩下的数据求平均值得到新的数据,此方法能有效抑制对周期性干扰^[8],中值滤波结果如图3(c)所示。

$$\frac{t_1}{T_s} \leq PW \leq \frac{t_2}{T_s} \quad (1)$$

式中: PW 表示脉冲的幅宽; T_s 表示为每次采样时间。本文选择 $t_1 = 150 \text{ ms}$, $t_2 = 420 \text{ ms}$ 。

(2) 幅高 PH 的判断

由于不同传感器感知的加速度数据不同,在加速度 a 上也反映不同,导致计算有差异。使用逆推公式:

$$P_{\min} \leq \sum_0^n a \times t^2 \leq P_{\max} \quad (2)$$

式中: n 表示采样数; a 为采样值; t 为采样周期; $P_{\min}$ 为按压最小值; $P_{\max}$ 为按压最大值。本文选择 $P_{\min} = 5 \text{ cm}$, $P_{\max} = 6 \text{ cm}$ 。

(3) 梯度的判断

规定一个脉冲的梯度变化过程为负-正-负,表现为二阶导数存在 2 个极值点且极小值点 $\min_1$ 在极大值点 $\max_2$ 之前。

上述 2 个点与横坐标位于此两者之间的曲线的均值点 $stdval$ 构成 3 个斜率,由于本文采用的是 ADXL345 的

5 ms 采样,因而需符合 min_1 与 $stdval$ 的斜率, $stdval$ 与 max_2 的斜率, min_1 与 max_2 的斜率。依次对 18 组实验数据进行脉冲识别与波形分割,最终得到 975 次心脏胸外按压的波形,如图 4(a) 所示。




图4 波形对其方式转换

Fig.4 Waveform conversion

3 基于加权方差的弱监督学习策略

本实验采用超声波测量得到的按压距离对按压进行评估,获取数据标签。由于人工按压过程中难免存在测距遮挡、抖动等问题,同时部分情况下按压测距难以达到毫米级的高精度,造成部分数据标签的缺失,为了解决训练集标签不完善的问题,本文提出一种基于加权方差的弱监督学习策略修正实验数据标签。

由图 4(a) 可知,预处理后的加速度数据波形并不容易观察离散情况,因而将所有按压曲线进行平移,从原点

对齐转换为最大值对齐,如图 4(b) 所示。

为了防止出现缺失值,将转换后每条曲线以最大值为界左边取 50 个点,右边取 20 个点构成数据集。初步分析含有标签的数据曲线及最大值对齐图形发现,按压规范有效时,波形相似度较高,集中体现在波形 2 个极值点处于所有波形的中间位置;按压距离差距超过 5 mm、按压中间出现较大抖动或按压间歇过长时,其波形与标准波形存在着明显差异,集中体现在波形的 2 个极值点过于平缓或凸出,可以采用 2 个极值点处的方差来衡量数据的离散程度。同时考虑到用 2 个极值点衡量一条波形过于片面,在一定程度上考虑其他 68 个数据点的影响,对这 68 个点进行主成分分析(PCA)降维^[9-10]以保留相对重要的信息。

如表 1 所示,前 5 个主成分即可解释 97% 的原始信息,结合 2 个极值点处的方差构建加权方差模型:

$$weighted_var_i = var_{i1} \times w_1 + var_{i2} \times w_2 + var_{i3} \times w_3 + var_{i4} \times w_4 + var_{i5} \times w_5 + var_{imin1} \times 0.25 + var_{imax2} \times 0.25$$

(3)

$$var_{ij} = \frac{X_{ij} - u}{N}$$

(4)

$$w_j = \frac{50\% \times \text{主成分 } j \text{ 的信息百分比}}{97.387\%}$$

(5)

式中: N 表示总的按压波形个数,为 975; u 表示所有波形该主成分的平均值; X_{ij} 是波形 i 在主成分 j 中的取值; var_{ij} 是对于主成分 j , 波形 i 相对所有波形的方差; 在评估按压波形时,极值点与其余 68 个点各占一半权重,采用 PCA 降维后的 5 个主成分代替 68 个点的状况,而主成分的权重根据其信息占比决定,并根据总体信息占比进行修正; 最终得到每条按压波形的加权方差 $weighted_var$ 。

表 1 主成分分析结果

Table 1 Results of principal component analysis

主成分	起始特征值			提取的平方和载入			循环平方和载入		
	统计	变量占比/%	累计占比/%	统计	变量占比/%	累计占比/%	统计	变量占比/%	累计占比/%
1	48.465	68.260	68.260	48.465	68.260	68.260	40.634	57.231	57.231
2	14.819	20.872	89.133	14.819	20.872	89.133	14.897	20.982	78.213
3	2.508	3.533	92.666	2.508	3.533	92.666	8.741	12.311	90.524
4	1.799	2.534	95.199	1.799	2.534	95.199	2.577	3.630	94.153
5	1.553	2.187	97.387	1.553	2.187	97.387	2.296	3.233	97.387
6	0.843	1.187	98.574						
7	0.396	0.557	99.131						
8	0.176	0.248	99.379						

如图 5 所示,将加权方差最低的 200 条曲线(偏离平均情况最小)标注为正确按压,将加权方差最大的 200 条曲线(偏离平均情况最大)标记为错误按压。

结合实验中超声波测距再评估得到修正的数据标签,将其中“标签缺失”或者测得按压距离大于 10 cm 的“明显错误标签”替换为模型对应的划分结果,若无对应




图5 加权方差模型划分结果

Fig.5 Partition results of weighted variance model

的划分结果,则直接舍弃,从而对数据标签进行修正,解决了部分数据标签缺失、可信度低的问题。

4 一维卷积神经网络结构

不同于传统的二维卷积神经网络,本文的输入为一维波形数据,因此卷积核也应采用一维结构,为了只对于单次按压波形进行处理,本文设计的第1层卷积核只对样本维度进行一维特征提取,而在 channel、batch 维度上不进行卷积计算,在第2次卷积时,同时考虑上一次卷积

的不同卷积核对同一样本提取的不同特征,因而在 channel 和样本两个维度上进行卷积,但本质上仍是对于一次按压波形数据的计算。池化过程与二维卷积网络也有所不同,本文采用一维池化,只对于单个样本这一个维度进行池化。此措施防止不同按压波形之间的干扰。在全连接层进行拼接时,由于本文采用一维卷积神经网络,不再需要将特征图重置成一维向量,所有特征图都呈现一维结构,直接前后连接即可。

具体网络结构如图6所示,一组输入数据分为 m 个样本,每个样本包含 70 个特征点,首先通过第1层卷积层,采用 32 个一维单通道卷积核进行信息提取,卷积核大小为 $1 \times 5 \times 1$,卷积步长均为 1,使用 Relu 激活,为了防止丢失边缘信息同时保证输入输出维度一致,采用 same padding 进行填充。通过第1层卷积层后通道数从 1 扩展为 32,每个通道保持 $m \times 70$ 个特征点不变;接着通过 1 个 max pooling 层进行下采样,采样窗口大小为 $1 \times 2 \times 1$,即不在 channel 和 batch 上池化,仅在单个样本中进行一维池化;然后再用 64 个大小为 $1 \times 5 \times 32$ 的卷积核进行信息提取,同样采用 Relu 进行激活后通过 1 个 max pooling 层池化,之后将 64 个不同通道首尾相连(即将每个样本重置为 1 维向量),再通过 1 个 128 个节点的全连接层和 1 个 Softmax 层完成分类并输出分类结果。




图6 一维卷积神经网络的详细结构

Fig.6 Detailed structure of the one-dimensional convolutional neural network

5 模型的优化方法

5.1 使用 Mini-batch 梯度下降策略以及滑动平均模型

初步对模型进行训练后发现存在训练时间长、参数更新慢的缺点,为了加速训练,本文采用输入数据向量化^[11]及 Mini-batch 梯度下降策略^[12],图6中 m 代表 1 个 batch 的大小。同时为了打乱数据集,在每轮训练开始前随机化分配每个 batch 中的数据。为了增强模型的鲁棒性,本文采用滑动平均模型^[13]进行优化,维护一个影子

变量来记录其滑动平均值,影子变量的值是当前值和更新后的值之间的一个值,这样可以限制参数的更新速度,让更新比较缓慢、稳妥。

$$\text{shadow_variable} = \text{shadow_variable} \times \text{decay} + (1 - \text{decay}) \times \text{variable} \quad (6)$$

式中: variable 为待更新参数; decay 为衰减率,决定了模型更新的速度, decay 越大,模型更新越慢,越稳定。但是在训练初期会导致更新比较慢,因此采用 num_step 动态设置 decay 的大小,使之在训练初期更新也比较快,每次使用的衰减率为:

$$\min\left(decay, \frac{1 + num_step}{10 + num_step}\right) \tag{7}$$

5.2 使用 Adam 优化算法

为了更好地更新网络参数,本文采用 Adam 优化算法代替随机梯度下降算法来最小化损失函数。随机梯度下降算法保持单一的学习率更新所有的权重,学习率在网络训练过程中并不会改变。而 Adam 优化算法结合了 momentum 和 RMSprop 梯度下降算法的优点,通过计算梯度的一阶矩估计值和二阶矩估计值为不同的参数设计独立的自适应性学习率^[14];此外,Adam 算法具有很高的计算效率和较低的内存需求,对于除学习率外其他参数的调试要求较低,可以较为方便地使用。

5.3 使用学习率衰减策略

若学习率设置得过大,在算法优化的前期会加速学习,使得模型更容易接近局部或全局最优解。但是在后期会有较大波动,甚至出现损失函数的值围绕最小值徘徊的问题,始终难以达到最优。经测试直接使用 Adam 算法损失函数的波动仍然较大,为了进一步优化模型,本文在 Adam 优化算法的基础上采用指数下降的学习率衰减策略^[15],使得学习率随着训练步数逐渐减小。

$$\alpha = \alpha_0 \times decay_rate^{\frac{global_steps}{decay_step}} \tag{8}$$

$$decay_steps = \frac{N}{m} \tag{9}$$

式中: α 为学习率; α_0 为初始学习率; $decay_rate$ 为衰减因子; $global_steps$ 为当前训练步数; N 为整个训练集样本个数; m 为一个批处理中的样本数目。

5.4 使用正则化策略

为了防止在训练过程中出现过拟合(低偏差、高方差)的情况,需要进行正则化处理,一种方法是在计算损失函数时加入表示模型复杂度的指标,进行正则化。若用 $J(\theta)$ 表示训练数据上的损失函数,那么在优化时不直接优化此函数,而是优化 $J(\theta) + \lambda R(w)$, 其中 $R(w)$ 为正则化项, λ 为正则化系数,表示正则化损失在总损失中的比例。常用的有 L1 和 L2 正则化。

L1 正则化^[16]:

$$R(w) = \|w\|_1 = \sum_i |w_i| \tag{10}$$

L2 正则化^[17]:

$$R(w) = \|w\|_2^2 = \sum_i w_i^2 \tag{11}$$

由于 L1 正则化不可导且优化带 L1 正则化的损失函数更加复杂,而 L2 正则化公式可导且优化方式简便多样,故本文采用 L2 正则化进行实验,将图 6 神经网络结构中的全连接层和 Softmax 层的权重加入 L2 正则化。另外常用的 Inverted Dropout 正则化方法^[18]是通过修改神经网络本身来实现的,即在进行反向传播时,根据设定的

保留概率使部分神经元节点随机失活,同时节点的输出需要除以保留概率达到缩放修正的目的。Dropout 在实践中能很好工作是因为其在训练阶段阻止神经元的共适应,同时由于 Dropout 不会阻止参数增长和彼此压制,应用 L2 正则化可以起到作用,故本文将全连接层中加入 Inverted Dropout 正则化。

6 实验与分析

6.1 学习率调试实验

如图 7 所示,在不采取学习率衰减策略下,分类的正确率波动很大,始终难以达到最优,而在采取学习率衰减后,尽管由于同时采取了 mini-batch 策略加速训练, cost function 并不是单调递减,分类正确率也有较小波动,但正确率整体呈上升趋势。对比不同 α_0 和 $decay_rate$ 下分类正确率的变化可知,当初始学习率较大时,正确率上升较快,但最后到达 cost function 最优值附近的分类正确率未必最高。综合而言,本文选择 $\alpha_0 = 0.005$, $decay_rate = 0.98$, 此时分类正确率可以达到 99.4%。




图7 不同学习率和衰减率下的分类正确率

Fig.7 Classification accuracy with different learning rates and attenuation rates

6.2 正则化策略调试实验

将原来按组排列的单次按压加速度波形数据打乱,随机选取 70% 和 30% 的数据分别作为训练集和测试集。表 2 所示为在相同训练集和测试集上使用不同正则化技术的结果,由于随机初始化的影响,采用 10 次实验取平均值的方法降低误差,显然同时使用 L2 正则化和 Inverted Dropout 的正确率更高,因此本文采用 L2 正则化与 Inverted Dropout 相结合的方法防止过拟合。

表2 不同正则化对分类正确率的影响

Table 2 The effectiveness of different regularization on classification correctness (%)

正则化方法	训练集正确率	测试集正确率
无	99.5	92.5
L2 正则化	98.5	94.2
Inverted Dropout	99.6	97.5
L2 正则化+Inverted Dropout	99.4	98.8

6.3 对模型参数调试的实验

本文使用的滑动平均模型、Inverted Dropout 等方法含有多个超参数,需要对各个超参数进行对比调参实验,由于篇幅有限,不再给出具体实验过程,表 3 所示为本文对模型参数调试的实验结果。

表 3 一维卷积神经网络参数设置

Table 3 Parameter setting of one-dimensional convolutional neural network		
参数名称	代表含义	参数取值
m	一个批处理中的样本数目	40
$decay$	滑动平均衰减率	0.98
α_0	初始学习率	0.005
$decay_rate$	学习率衰减速率	0.98
λ	L2 正则化参数	0.000 1
$keep_pro$	dropout 保留概率	0.8

6.4 与其他算法的对比实验

为了比较本文提出的基于一维卷积神经网络的心脏胸外按压波形识别方法与传统方法相比的优势,在相同数据集上多次进行实验,得到结果如表 4 所示。

表 4 不同算法的正确率

Table 4 Correctness of different algorithms (%)	
识别算法	正确率
Logistics 回归	74.64
基于加速度二次积分的距离判断	89.20
单隐层的神经网络	78.24
多隐层的神经网络	<95
决策树算法	97.25
一维卷积神经网络	99.40

经测试,传统的基于波形划分和位移计算的方法,正确率只能达到 89.2%;7 层以内 BP 神经网络模型正确率也不足 95%,且隐藏层节点个数变化范围较大难以确定。本文提出的基于波形划分和一维卷积神经网络的分类模型可以将分类错误率降低到 1%以内,极大地提升了心脏胸外按压波形的识别正确率,并且模型具有较好的鲁棒性和泛化能力。

6.5 可视化分析

为了观察每一个卷积核具体提取了何种特征,本文对卷积网络的特征图进行分析。

图 8(a)所示为输入的按压加速度变化曲线,经过第 1 个卷积层后得到的 32 个特征图可分为 5 类,其中有 5 个属于类别 1,表示提取到了错误的特征,其特征值为负

数,经过 Relu 激活后清零,不会传入下 1 层;有 16 个属于类别 2,其提取的是整体波形的特征,整体形状与输入曲线相似,但幅值减小,其作用类似于滤波器;有 7 个属于类别 3,表示边缘检测,对波形的起始或结尾进行特征提取;另外分别还有 2 个属于类别 4 和类别 5,分别表示提取波谷、波峰特征。




图 8 第 1 层卷积特征图与输入波形的对比
Fig.8 Comparison of the first layer of convolutional features and the input waveform

加速度波形曲线经过第 2 层卷积层得到 64 个特征图,图 9(a) ~ (d)所示为 4 类的大致形状,与图 8 相比,特征图尺寸减小,不再具有明显的曲线特征,部分的凸起表明第三层卷积是对曲线的某几个小部份进行特征提取,而不再对于整条曲线。

为进一步分析原输入曲线的哪些部分让卷积神经网络做出最终的分类决策,本文使用 Grad-CAM 算法进行了类激活图可视化,生成类激活的热力图来表示输入数据每个位置对最终分类类别的重要程度^[19],原有的 Grad-CAM 方法仅适合找到二维输入图像的类激活图,本文对其进行改进,使其能适用于一维波形输入数据。首先,在寻找原输入曲线的哪些部分对卷积神经网络做出





图9 第2层卷积特征

Fig.9 Feature map of the second layer of convolution

了最终的分类决策影响最大时,应寻找所有加速度按压波形中的通用特征,因此将训练时一个 batch 中全部波形作为一个样本输入网络,利用最后一层卷积层中特征图(见图9)的信息,用类别相对于通道的梯度对这个特征图中的每个通道进行加权,相加后再通过一个 Relu 激活,得到类激活的热力图,如图10所示。其中 Relu 函数的作用是只关心对类别有正影响的那些区间^[20],让得到的热力图反映出一条波形哪几部分的特征,让神经网络将该波形分类为“正确的按压”。再将热力图进行上采样后和原输入曲线进行叠加,使得曲线不同部分用不同颜色表示,为了更方便地观察,在最终叠加图中将曲线的颜色进行纵向拓展,使得图像不同区间用不同颜色(不同标记)代表对最终分类结果的不同影响程度,颜色越浅(▲标注)代表影响程度越大。

图10中,颜色较浅(▲标注部分)的3个区域为横坐标取值为[0,8]、[23,42]、[52,66]3个区间段,结合波形分割的过程,可归纳为2阶段,物理含义为在利用胸外按压加速度曲线评估本次按压是否规范时,卷积神经网络所关注的特征集中于开始按压至按压到达平衡位置,以及此次按压松手后反向加速度达到最大值至下一次按压开始这2个阶段的加速度波形情况。



注:输入应为一个 batch 中所有曲线作为一个样本,以便利用可视化找出普遍特征,但图中为了方便观察,仅画出一条波形曲线

图10 一维 grad-CAM 可视化

Fig.10 One-dimensional grad-CAM visualization

7 结 论

本文在波形分割和弱监督学习的基础上,使用一维卷积神经网络完成心脏胸外按压波形识别。首先对原始

数据进行去噪滤波处理,使用滑动窗口模型识别脉冲、分割波形,得到起点对齐的按压波形,随后提出一种基于加权方差的弱监督学习策略修正数据标签。构建一维卷积神经网络,使用 Adam 算法、Dropout 和 L2 正则化、学习率衰减等方法对模型进行优化。结果表明,卷积神经网络

达到了 99.4% 的 mAP。进一步使用 Grad-CAM 方法进行可视化分析得出对结果影响较大的 2 个阶段。本文提出的模型在应用过程中通过加速度传感器获得数据,不受按压遮挡、抖动的影响,在复杂环境中具有较好鲁棒性;同时具有装置简单、便于携带等优点,可以在非医疗场所的心脏按压急救中实时评估按压效果。

在实际心脏胸外按压急救中,对于不同的年龄阶段、不同的病症类型,按压方法存在差异,例如救助溺水者常采用 30 次胸外按压辅以 2 次人工呼吸,而救助触电人员需要较为急促的按压,一般为 100~120 次/min。下一步的研究需要结合病患的具体情况对心脏胸外按压是否规范有效做进一步的评估。

参考文献

- [1] BOUSSEN S, IBOUANGA-KIPOUTOU H, FOURNIER N, et al. Using an inertial navigation algorithm and accelerometer to monitor chest compression depth during cardiopulmonary resuscitation[J]. Medical Engineering & Physics, 2016, 38(9): 1028-34.
- [2] 钱绍文, 郑捷文, 张广, 等. 基于加速度二次积分的胸外按压深度测量[J]. 北京生物医学工程, 2011, 30(5): 496-501.
QIAN SH W, ZHENG J W, ZHANG G, et al. The depth measurement of chest compression based on double integration of acceleration [J]. Beijing Biomedical Engineering, 2011, 30(5): 496-501.
- [3] 吴豪杰, 吴水才, 刘忠英. 基于加速度波形形态分析的胸外按压深度检测研究[J]. 中国医疗设备, 2018, 33(3): 6-10.
WU H J, WU SH C, LIU ZH Y. Study on the detection of chest compression based on acceleration waveform shape analysis [J]. China Medical Devices, 2018, 33(3): 6-10.
- [4] RUSSELL J, ZIVE D, DAYA M. Effect of chest compression leaning on accelerometry waveforms [C]. Proceedings of the Computing in Cardiology Conference, 2017
- [5] 刘攀, 张辉, 雷龙, 等. 加速度数据的采集及分析[J]. 信息技术, 2013(12): 110-112, 116.
LIU J, ZHANG H, LEI L, et al. Acquisition and analysis of acceleration[J]. Information Technology, 2013(12): 110-112, 116.
- [6] 韩萍, 桑威林, 石庆研. 一种新型非线性卡尔曼滤波方法[J]. 仪器仪表学报, 2015, 36(3): 632-638.
- [7] HAN P, SANG W L, SHI Q Y. Novel nonlinear Kalman filtering method [J]. Chinese Journal of Scientific Instrument, 2015, 36(3): 632-638.
- [8] WANG M, TONG W, LIU S. Fault detection for power line based on convolution neural network [C]. Proceedings of the International Conference on Deep Learning Technologies, 2017.
- [9] 张建明, 李沛, 李旭东, 等. 结合中值滤波与稀疏表示的混合去噪算法[J]. 计算机工程, 2016, 42(9): 240-245.
ZHANG J M, LI P, LI X D, et al. Hybrid denoising algorithm combining median filtering with sparse representation[J]. Computer Engineering, 2016, 42(9): 240-245.
- [10] DUAN S, CHEN K, YU X, et al. Automatic Multicarrier Waveform Classification via PCA and Convolutional Neural Networks[J]. IEEE Access,
- [11] YU J, SI Y, XIN L, et al. ECG identification based on PCA-RPROP [C]. Proceedings of the International Conference on Digital Human Modeling and Applications in Health, Safety, Ergonomics and Risk Management, 2017.
- [12] REN J S, LI X. On vectorization of deep convolutional neural networks for vision tasks[J]. Computer Science, 2015, arXiv:1501.07338.
- [13] KHIRIRAT S, FEYZMAHDAVIAN H R, JOHANSSON M. Mini-batch gradient descent: Faster convergence under data sparsity [C]. Proceedings of the IEEE Conference on Decision & Control, 2017.
- [14] 刘攀, 楼光海, 黄微. 结合双树复小波变换和滑动平均滤波的心电信号去噪方法[J]. 电子测量技术, 2018, 41(19): 112-117.
LIU J, LOU G H, HUANG W. ECG signal denoising with combination of dual-tree complex wavelet transform and moving average filter [J]. Electronic Measurement Technology, 2018, 41(19): 112-117.
- [15] ZHANG R, BAO H, SUN H, et al. Recommender systems based on ranking performance optimization [J]. Frontiers of Computer Science, 2016, 10(2): 270-80.
- [16] 赵建民, 王雨萌. 基于 BP 神经网络学习率优化的研

- 究[J]. 微型电脑应用, 2018, 34(8): 89-92.
- ZHAO J M, WANG Y M. The study of learning rate based on BP neural network [J]. Microcomputer Applications, 2018, 34(8): 89-92.
- [16] WEI Q J, WANG W B. Research on image retrieval using deep convolutional neural network combining L1 regularization and PRelu activation function [C]. IOP Conference Series Earth and Environmental Science, 2017.
- [17] 吕炜, 陈永刚, 沈晨. 带 L2 正则化项的神经网络逆向迭代算法收敛性分析[J]. 信息技术与信息化, 2015 (6): 183-184, 186.
- LYU W, CHEN Y G, SHEN C. Convergence analysis of neural network reverse iterative algorithm with L2 regularization term [J]. Information Technology and Informatization, 2015(6): 183-184, 186.
- [18] KENWARD M G. Selection models for repeated measurements with non-random dropout: An illustration of sensitivity[J]. Statistics in Medicine, 2015, 17(23): 2723-2732.
- [19] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: Visual explanations from deep networks via gradient-based localization [C]. IEEE International Conference on Computer Vision, 2017.
- [20] SPRINGENBERG J T, DOSOVITSKIY A, BROX T, et al. Striving for simplicity: The all convolutional net[J]. Computer Science, 2014, arXiv:1412.6806.

作者简介



鲍宇, 1999 年于中国矿业大学获得学士学位, 2011 年于同济大学获得博士学位, 现为中国矿业大学副教授, 主要研究方向为群体智能方法理论与应用和分布式网络。

E-mail: baoyu@cumt.edu.cn

Bao Yu received his B. Sc. degree from China University of Mining and Technology in 1999, and Ph. D. degree from Tongji University in 2011. He is currently an associate professor at China University of Mining and Technology. His main research interests include the theory and application of swarm intelligence and distributed network.