

DOI:10.19651/j.cnki.emt.2005319

久坐人群无器械训练动作识别与计数算法研究*

王威^{1,2} 孙少明^{1,3} 孙怡宁¹ 陈超^{1,2} 陈竟成^{1,2} 张海涛¹

(1.中国科学院合肥物质科学研究院合肥230031; 2.中国科学技术大学合肥230026;

3.中科院合肥技术创新工程院合肥230088)

摘要:针对久坐人群长期缺乏运动导致身体呈现亚健康状态和现有训练方法缺乏监督性的现状,提出一种人体动作识别与计数方法实现4种无器械训练动作精准识别与计数。以手机摄像头捕获训练者的视频信息作为输入,通过BlazePose网络模型处理得到的人体骨骼点数据经过数据滤波处理、特征提取后,利用3种常见的机器学习算法进行动作分类,将分类的结果结合骨骼信息,采用检测波峰波谷计数算法统计训练动作的完成次数。实验结果表明,采用GBDT算法得出动作识别率为96.5%,计数算法准确率为98.9%,具有良好的实际应用价值。

关键词:久坐人群;动作识别;骨骼数据;动作计数

中图分类号: TP2 **文献标识码:** B **国家标准学科分类代码:** 520.5099

Research on the recognition and counting algorithm of sedentary people's training without equipment

Wang Wei^{1,2} Sun Shaoming^{1,3} Sun Yining¹ Chen Chao^{1,2} Chen Jingcheng^{1,2} Zhang Haitao¹

(1.Hefei Institutes of Physical Science, Chinese Academy of Sciences, Hefei 230031, China;

2.University of Science and Technology of China, Hefei 230026, China;

3.CAS(Hefei) Institute of Technology Innovation, Hefei 230088, China)

Abstract: In view of the current situation that sedentary people lack of exercise for a long time, resulting in sub-health state and the lack of supervision of existing training methods, this paper proposes a method of human motion recognition and counting to realize the accurate recognition and counting of four kinds of training without equipment. Taking the video information of the trainer captured by the mobile camera as the input, the human skeleton point data processed by the BlazePose network model is processed by data filtering and feature extraction, and three common machine learning algorithms are used for action classification. The classification results are combined with the bone information, and the peak and trough counting algorithm is used to count the number of training actions completed. The experimental results show that: using GBDT classification algorithm, the action recognition rate is 96.5%, and the accuracy of counting algorithm is 98.9%, which has good practical application value.

Keywords: sedentary people; action recognition; bone data; action count

0 引言

久坐行为是指人在清醒时进行的包括工作、学习、电子娱乐等一系列静态行为^[1]。在日常生活和工作中,久坐行为为变得越来越普遍。久坐的群体大多为学生和室内办公人员。长期坐在课桌前或电脑前,缺乏一定量的体育运动,导致身体呈现亚健康状态。Loprinzi^[2]的研究表明,对于成年人,久坐的时间越长,患多病的风险也越大。雷雅麟等^[3]的研究表明,当每天静坐时间超过3h,患消化系统疾病的概

率与静坐时间呈正相关。由此可见,久坐行为在慢慢地损伤人体的各项机能。

目前针对体能锻炼常见的方式有两种,第1种是健身房等专业的运动场所,但久坐人群由于工作或学习压力,缺乏完整的时间去这些专业的场所完成训练。第2种是Keep等健身软件,通过语音播报和视频引导的形式,无需借助任何运动器械,利用碎片化的时间即可完成训练。但这种训练方式比较枯燥乏味,在训练过程中缺乏动作识别功能,无法得知训练者是否完成训练动作,缺乏监督性。同

收稿日期:2020-11-05

* 基金项目:中国科学技术大学智慧城市研究院(芜湖)科技成果转化项目(2019ZX01)、国家重点研发计划(2018YFC2001304)项目资助

时需要训练者人工计算动作的完成次数,缺乏自检性。因此需要探究一种新的训练监督和自检方法,用于弥补传统训练方法的不足。

人体动作识别作为近几年的热门研究方向之一,目前关于人体动作识别的方法主要分为两种。第 1 种是基于穿戴设备来获取人体的运动信息,完成动作识别^[4]。例如曹书敏^[5]提出利用智能可穿戴设备中内置的各类传感器,建立两套系统对人体动作进行识别分类。王远^[6]提出利用惯性传感器信息和表面机电信号完成下肢多关节动作识别。但采用穿戴式设备会给人体带来诸多不便,不利于推广和实际使用。第 2 种是基于图像^[7],最典型的案例就是利用微软的 Kinect 设备,完成动作识别。辛义忠等^[8]提出一种利用 Kinect 平台,基于特征选择的模板识别方法。李顺等^[9]提出一种基于关键帧和人体骨骼点信息的动作识别算法。单台 Kinect 摄像头在人体产生遮挡时,识别率会大大降低。宋震^[10]提出一种基于三台 Kinect 的三维人体骨提取和动作识别算法,提升了识别率。基于 Kinect 的动作识别方法虽然解决了穿戴式设备给人体带来的不方便问题,但由于需要依赖 Kinect 设备和电脑,不具备便携性。

随着近几年深度学习的发展和智能手机的兴起,越来越多的神经网络开始应用于手机移动端设备。其中谷歌开源的 BlazePose^[11]就是应用于手机端,识别人体姿态信息的神经网络模型。本文将采用 BlazePose 结合手机摄像头采集人体的骨骼点位置信息,对骨骼点信息进行特征提取。采用传统的机器学习算法,对 4 种无器械训练动作:双臂伸展、开合跳、深蹲、跳绳,和用于状态转换的站立动作,共 5 种动作进行动作识别。同时提出一种动作计数算法统计训练动作的完成次数。本文提出的算法可直接运行在手机上,不依赖其他设备,结合无器械的训练方式,即可完成久坐人群的监督训练。

1 动作识别算法

整体算法流程如图 1 所示,包含实验和应用两部分。这两部分的共同点在于,都需要经过手机摄像头采集训练过程中的视频信息,经过数据处理后得到 160 维特征。不同点在于,对于实验部分,需要将这 160 维特征输入到机器学习分类算法中训练,将训练得到的分类模型保存到本地,同时验证分类算法和动作计数算法的准确性,证明该算法的有效性。对于应用部分,则直接将特征输入到上述保存下来的模型中,得到分类结果,再结合计数算法,完成对训练过程的监督和自检。

1.1 数据获取

数据的采集工作通过自己开发的数据采集系统 App 完成,数据采集的工作流程如图 2 所示,在采集开始之前,需要利用手机支架将手机固定在距离训练者 2 m 左右的位置,保证手机可以捕获到训练者全身的视频信息。其中视频信息可以看成是一帧一帧的图片,将视频流中的每帧图

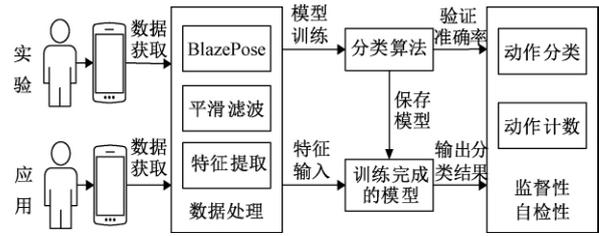


图 1 算法流程

片经过图像变换后,输入到 BlazePose 网络模型中,进而得到每帧图片中人体的骨骼点数据,将骨骼点数据存储到 Excel 表格中。

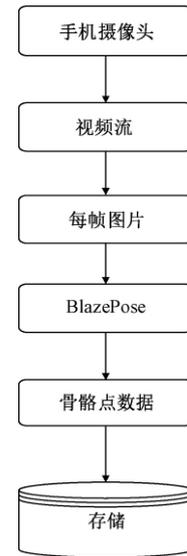


图 2 数据采集流程

BlazePose 是谷歌 2020 年提出的用于边缘设备上运行的单人人体姿态估计算法。在本实验采用的手机(麒麟 985 处理器,8 G 运行内存)上运行 BlazePose 模型可以达到 23 帧左右的帧数,可以用于实时计算场景。BlazePose 可以输出人体的 33 个骨骼关节点位置信息,具体输出的骨骼关节点信息如图 3 所示。

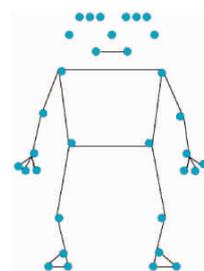


图 3 BlazePose 输出的骨骼关节点

1.2 数据预处理

基于 BlazePose 模型获取到的骨骼关节点,在帧与帧

之间,存在骨骼关节的抖动问题,因此需要对采集到的原始数据进行滤波处理^[12]。这里采用的是简单、快速的滑动窗口均值滤波算法,具体算法如下。

1) 设定滑动窗口的窗口大小和步长,在本文中,窗口的大小设置为 5,移动的步长为 1。

2) 假设数据总帧数为 N ,从第 i 帧($2 < i < N - 2$)开始,以第 i 帧数据为中点,向前后各选取 2 帧数据,一共 5 帧数据构成一个窗口。

3) 计算步骤 2) 中,窗口中数据的平均值 x_i ,将 x_i 作为第 i 帧数据滤波后的数值。

4) 重复步骤 2) 和 3),继续处理 $i + 1$ 帧的数据,直到 i 到达边界位置($i = N - 2$)。

1.3 特征提取

人体动作是一系列时间维度上的骨骼关节运动轨迹的集合^[13],因此想要完成人体动作的识别,需要加入时间维度上的信息。本文采用滑动窗口来表示时间维度上的信息。针对要识别的 5 种动作,完成每个动作所需要的时间都在 2 s 以内,同时根据 BlazePose 在本实验采用的手机上采样频率为 23 帧/s 左右,这里将滑动窗口的大小设置为 40 帧,即把接近 2 s 的数据作为一个窗口。为了提升识别的准确率,防止窗口大小分割不合理带来的影响,这里把滑动窗口的步长设置为 20 帧数据,让窗口尽可能地包含动作序列时间维度上的特征。

1) 特征 1

对于这 5 种动作,站立和双臂伸展在运动的过程中,人体在垂直方向上不会出现明显的变化,但是对于跳绳和深蹲动作,会呈现周期性的变化。针对这个运动特性,将人体运动过程中垂直方向的变化值作为模型训练的特征。这里用骨骼关节中鼻子 y 轴坐标值来表示人体垂直方向的位置信息。具体数值随帧数的变化如图 4 所示。

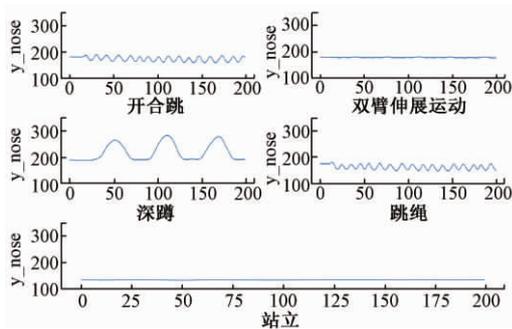


图 4 5 种动作 y_{nose} 数值

假设动作开始时鼻子的坐标和当前时刻鼻子的坐标分别为 $(x_{start_nose}, y_{start_nose})$ 和 (x_{nose}, y_{nose}) 。因此鼻子 y 轴坐标的变化量构成的特征 f_1 :

$$f_1 = y_{nose} - y_{start_nose} \quad (1)$$

2) 特征 2

对于深蹲动作,人体的膝盖与脚部垂直方向数值的差

值会呈现明显的周期性变化,且变化幅度较大。因此可以选择膝盖与脚部垂直方向的差值作为特征 f_2 。由于人体运动过程中,左右关节可以看成是近似对称的,所以在计算特征时,只选取左半身数据即可,假设左半身膝盖和脚的坐标为 (x_{knee}, y_{knee}) 和 (x_{foot}, y_{foot}) ,则有:

$$f_2 = y_{knee} - y_{foot} \quad (2)$$

3) 特征 3

在开合跳运动中,手部会周期性地经过鼻子的上方和下方,因此将其差值作为特征 f_3 :

$$f_3 = y_{hand} - y_{nose} \quad (3)$$

4) 特征 4

在运动过程中,肩膀和手肘的夹角也是一个重要的特征 f_4 。假设肩膀和手肘关节的坐标为 $(x_{shoulder}, y_{shoulder})$ 和 (x_{elbow}, y_{elbow}) ,则肩膀和手肘之间的夹角 θ 为:

$$\cos(\theta) = \frac{x_{shoulder} \cdot x_{elbow} + y_{shoulder} \cdot y_{elbow}}{\sqrt{x_{shoulder}^2 + y_{shoulder}^2} \cdot \sqrt{x_{elbow}^2 + y_{elbow}^2}} \quad (4)$$

经过上述 4 个步骤,在每帧数据上各提取了 4 个特征值,由于采用的是滑动窗口的方式,每个窗口的大小为 40 帧数据,因此一个窗口共包含 160 维特征数据。

1.4 分类算法

分类算法选取了 3 种常见的机器学习算法,用来做对比实验,筛选出分类效果最好的分类器,作为后面动作计数算法的基础。

1) KNN

KNN(K-nearest-neighbor)通过测量不同特征值之间的距离来进行分类。KNN 和其他分类算法不一样,KNN 算法没有训练学习的过程。它的工作原理是利用训练数据对特征向量空间进行划分。对于本实验,KNN 会被划分为 5 种类别,当利用 KNN 进行分类预测的时候,计算出与预测数据特征距离最近的 K 个训练数据,根据这 K 个训练数据对应的类别,利用投票法,输出最终的预测类别结果。

2) 随机森林

集成学习是一种将多个弱学习器进行结合,形成强学习器的算法。典型的代表有两类:Boosting 和 Bagging。其中 Boosting 算法的弱学习器间存在很强的依赖关系,需要串行的方式去执行训练过程。而 Bagging 算法弱学习器之间不存在强依赖关系,可以并行的执行训练过程。随机森林是一种属于 Bagging 类型的算法,既可以用来完成回归任务,也可以用来完成分类任务。随机森林是用随机的方式去构建一个森林,这个森林是由很多个不存在强依赖关系的决策树组成,利用有放回采样的方法,从训练集中选取出 T 个包含 m 个训练样本的采样集,去训练对应的决策树。然后将多个决策树输出的结果进行投票,作为随机森林最终的结果输出。

3) GBDT

Boosting 是集成学习方法的另一种代表性算法。其中梯度提升树(gradient boosting decision tree,GBDT),就是

一种基于 Boosting 思想,将弱学习器提升为强学习器的算法。在这里虽然采用 GBDT 算法来实现分类任务,但是采用的弱学习器是 CART 回归树。之所以不选用 CART 分类树,是因为 GBDT 每次在迭代的时候,需要拟合梯度值,是一个连续值,因此只能采用回归树,而不是分类树。

2 计数算法

根据上文的分类结果,可以得到训练者在每个时刻所做的动作。由于训练者在训练过程中,每个训练动作都会有相应的特征呈现周期性的变化^[14]。因此可以根据特征数据中对应的波峰波谷个数,来判别训练者完成动作的次数^[15]。站立动作作为各个动作的转换标志,因此不用考虑该动作的完成次数。其中开合跳、双臂伸展运动、跳绳 3 种动作的手肘部分都会呈现周期性的变化,因此将手肘 y 轴方向的数值作为计算这 3 种动作完成个数的依据。而深蹲过程中,人体鼻子 y 轴的数值会呈现周期性的变化,因此将人体鼻子 y 轴的数值作为计算深蹲动作完成个数的依据。

本文以开合跳动作为例,分析开合跳动作完成的次数。假设手肘 y 轴方向数值的集合为 Y_{elbow} ,第 i 帧数据的手肘 y 轴方向数值为 $y_{\text{elbow}}^{(i)}$ 。

1)用 STATE 标志记录此时的状态,STATE=1 代表上坡,STATE=2 代表下坡。将 STATE 初始化为 0。用队列 peak 存放所有波峰值,用队列 trough 存放所有波谷值。用 RANGE_SIZE 表示两个波峰之间、或者两个波谷之间的最小间隔,只有当此时波峰或波谷与前一个波峰或波谷的间隔大于 RANGE_SIZE 时,才会将此时的波峰或波谷记录到相应的队列中。

2)(1)当 STATE=0 时,如果 $y_{\text{elbow}}^{(i)} < y_{\text{elbow}}^{(i+1)}$,则说明此时处于上坡状态,则修改 STATE=1,否则修改 STATE=2。

(2)当 STATE=1 时,如果 $y_{\text{elbow}}^{(i)} > y_{\text{elbow}}^{(i+1)}$,则此时状态从上坡变成下坡,修改 STATE=2。此处为一个波峰,然后判断此时的波峰与上一个波峰的距离是否大于 RANGE_SIZE,若大于,则将此波峰加入到 peak 队列中。否则修改上一个波峰为当前的波峰值。

(3)当 STATE=2 时,如果 $y_{\text{elbow}}^{(i)} < y_{\text{elbow}}^{(i+1)}$,则此时状态从下坡变成上坡,修改 STATE=1。此处为一个波谷,然后判断此时的波谷与上一个波谷的距离是否大于 RANGE_SIZE,若大于,则将此波谷加入到 trough 队列中。否则修改上一个波谷为当前的波谷值。

3)重复步骤 2),直到遍历完 Y_{elbow} ,最后统计 peak 和 trough 队列的个数,取二者个数的平均值为动作的完成次数。

如图 5 所示为开合跳运动检测的波峰和波谷位置信息,其中圆点代表波峰,五角星代表波谷。

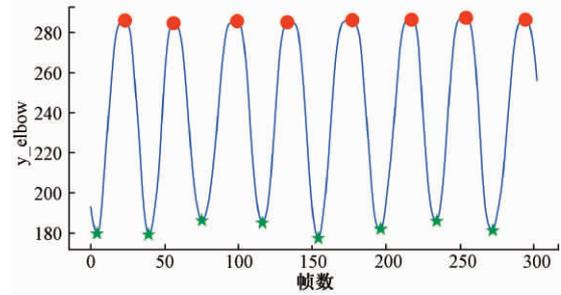


图 5 波峰波谷检测

3 实 验

为验证本算法的有效性,本文选取了 20 位测试人员(身高/cm: 172.4 ± 8.1 ,体重/kg: 63.2 ± 8.5 ,年龄: 24 ± 3.5)。每个测试人员将执行站立、双臂伸展、开合跳、深蹲、跳绳 5 种训练动作,其中每种训练动作执行 1 min。因为数据的采样频率在 23 帧/s 数据左右,因此针对每个动作得到约 27 600 帧的数据。

3.1 滤波实验与分析

由于 BlazePose 会输出 33 个骨骼关节的坐标信息,在本文特征提取中,只使用了其中一部分的骨骼关节信息,因此只需要对使用到的这部分骨骼关节信息进行滤波处理即可。以左肘部 y 轴数据为例,如图 6 所示为滤波前后的对比,其中实线为滤波前效果,虚线为滤波后的效果。可以看出滤波后的数据在没有改变数据形状的前提下,变得更加平滑,证明了滤波算法的有效性。

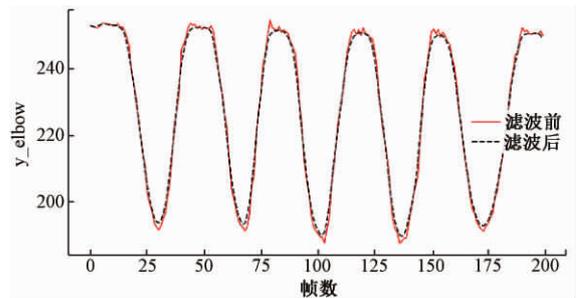


图 6 滤波前后效果

3.2 动作识别与计数算法实验分析

将这 20 位测试人员的测试数据,利用上文中提到的 3 种机器学习算法和计数算法,进行 10 折交叉验证,分别计算动作识别率和计数算法准确率。实验的流程如图 7 所示。

实验结果如表 1~4 所示,其中表 1、2、3 分别呈现了 3 种不同机器学习算法的识别率混淆矩阵,表 4 为 3 种算法的总识别率和对应计数算法的准确率。其中动作识别率 $P_{\text{classification}}$ 为:

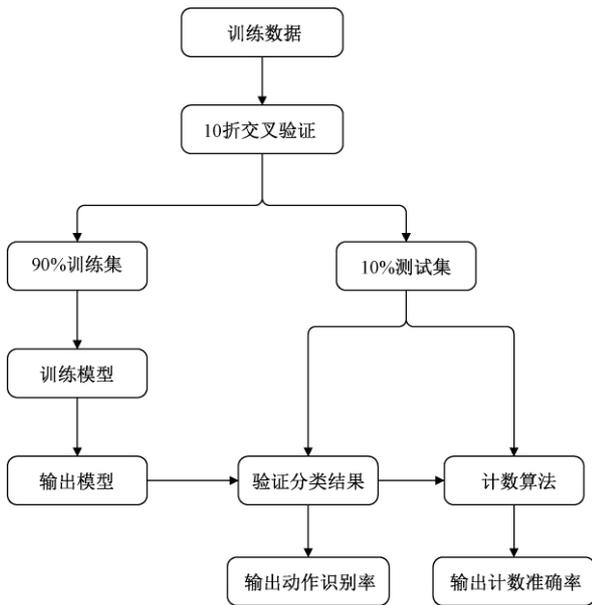


图 7 实验流程

$$P_{\text{classification}} = \frac{n_{ij}}{\sum_j n_{ij}} \quad (5)$$

其中, $0 \leq i, j \leq 4$, i 和 j 是 5 种待识别动作对应的标签。 n_{ij} 表示真实标签为 i , 识别为 j 的样本个数。

动作计数准确率 P_{count} :

$$P_{\text{count}} = \frac{N_{\text{pred}}}{N_{\text{all}}} \quad (6)$$

其中, N_{pred} 为每种训练动作经过动作分类算法识别后, 再经过动作计数算法统计出的动作完成次数, N_{all} 为人工统计得到该训练动作的真实完成次数。

表 1 KNN 算法分类结果的混淆矩阵

KNN 算法	识别率/%				
	开合跳	双臂伸展	深蹲	跳绳	站立
开合跳	<u>98.8</u>	1.2	0	0	0
双臂伸展	0	<u>99.8</u>	0	0.2	0
深蹲	0	0.4	<u>99.5</u>	0	0.1
跳绳	0	0.2	0	<u>88.3</u>	11.5
站立	0	0	0	0	<u>100</u>

表 2 GBDT 算法分类结果的混淆矩阵

GBDT 算法	识别率/%				
	开合跳	双臂伸展	深蹲	跳绳	站立
开合跳	<u>99.8</u>	0.2	0	0	0
双臂伸展	0.4	<u>99.6</u>	0	0	0
深蹲	0	0	<u>100</u>	0	0
跳绳	0.4	3.5	0	<u>96.1</u>	0
站立	0	13.0	0	0	<u>87.0</u>

表 3 随机森林算法分类结果的混淆矩阵

随机森林 算法	识别率/%				
	开合跳	双臂伸展	深蹲	跳绳	站立
开合跳	<u>98.3</u>	0.7	1.0	0	0
双臂伸展	0.2	<u>99.8</u>	0	0	0
深蹲	0.4	0.1	<u>99.5</u>	0	0
跳绳	10.4	0.2	0.2	<u>89.2</u>	0
站立	0	12.8	0	0	<u>87.2</u>

表 4 动作识别率与动作计数准确率

分类算法	识别率/%	计数准确率/%
KNN	97.3	96.6
GBDT	96.5	98.9
随机森林	94.8	96.7

由表 4 可以看出, 3 种分类算法中 KNN 的识别率最高, 但是对于计数准确率, 采用 GBDT 算法进行识别之后再计数的准确率最高。分析表 1、2、3 的 3 种识别算法混淆矩阵可以看出, 在使用 KNN 分类算法对跳绳动作进行分类时, 错误的将部分数据分类成了站立动作, 导致跳绳动作的计数准确率下降, 最终导致 KNN 算法的计数准确率低于 GBDT 算法。但 3 种算法识别率高于 94%, 计数准确率高于 96%。

虽然 KNN 的识别率高于 GBDT, 但由于 KNN 没有训练过程, 每次识别都需要进行距离的计算, 需耗费时间, 且不利于模型的移植, 因此本文最终并没有选择 KNN 算法, 而是选取识别率稍低于 KNN, 但对应的计数准确率高于 KNN 的 GBDT 模型, 作为最终的动作识别分类算法。

3.3 与其他方法的比较

传统的动作识别算法大多基于 Kinect 或者基于视频分析来实现。如表 5 所示, 方法 1: 李顺等^[9]利用 Kinect 获取到人体骨骼节点关键帧数据, 对 6 种常见的日常动作: 挥手、双手举起、前推、踢腿、站立、原地踏步进行分类实验, 识别率为 95.78%。方法 2: 张恒鑫等^[16]利用 OpenPose 获取人体骨骼点, 利用 KNN 模型对 Weizmann 数据库中的 10 种日常动作进行分类, 识别率为 88.93%。

表 5 与其他方法的比较

方法	类别	识别率	设备	便携性
方法 1	6 种	95.8%	电脑主机+Kinect	不便携
方法 2	10 种	88.9%	电脑主机+高性能显卡	不便携
本文方法	5 种	96.5%	智能手机	便携

相比于采用 Kinect 和 OpenPose 的动作识别算法, 本文提出的动作识别算法, 基于手机移动端 BlazePose 网络模型获取人体骨骼点^[16], 利用 GBDT 分类算法得出动作识

别率为 96.5%。该算法在保证动作识别率的基础上,克服了传统方法对电脑配置和外置设备的依赖。同时根据动作计数算法,可进一步判断动作的完成度。

4 结 论

久坐人群由于工作或学习原因,难以去健身房等专业的场所锻炼身体,导致运动量不足,身体容易呈现亚健康状态。针对这一现象,本文筛选了 4 种可以利用碎片化时间完成体能训练的无器械训练动作。同时提供了一种动作识别和计数算法。

该算法利用手机摄像头拍摄训练者的训练视频,将视频的每帧图像输入到 BlazePose 网络模型,实时获取到训练者的骨骼点位置信息,根据骨骼点进行数据滤波、特征提取后,最终采用 GBDT 分类算法进行动作识别,同时采用波峰波谷的计数算法,统计训练动作的完成次数,反馈给训练者,达到监督性和自检性的目的。经实验验证,该动作识别算法的识别率为 96.5%,计数算法的准确率为 98.9%。具有良好的实际应用价值。

相比于利用 Kinect 或可穿戴设备进行动作识别的算法,本文提出的算法基于手机端移动设备,训练者可以随时随地的利用碎片化时间,即可完成监督训练。不受设备的限制,具有很强的便携性和实用性。

当然本研究还存在很多不足之处,在以后的工作中可以根据久坐人群的五大核心体能要素,制定出更多的体能提升训练动作,在动作识别算法和计数算法的基础上,进一步的分析训练动作完成的标准度,提出动作标准度匹配算法。从而实现更加科学化的训练监督。

参考文献

- [1] 杨双燕,周强.久坐行为的流行病学研究与展望[J].中国运动医学杂志,2016,35(5):500-505.
- [2] LOPRINZI P D. Sedentary behavior and medical multimorbidity [J]. *Physiology & Behavior*, 2015, 151:395-397.
- [3] 雷雅麟,辛军国,杨春松,等.久坐行为与成年人多种慢性疾病的关联研究[J].现代预防医学,2020,47(17):3158-3163.
- [4] 张俊杰,孙光民,李煜,等.基于加速度传感器的上肢运动信息采集与姿态识别[J].北京工业大学学报,2017,

- 43(7):978-986.
- [5] 曹书敏.基于智能可穿戴设备的人体动作识别与交互[D].合肥:中国科学技术大学,2020.
- [6] 王远.基于表面肌电和惯性传感器信息的下肢多关节动作识别方法[D].深圳:中国科学院大学(中国科学院深圳先进技术研究院),2020.
- [7] 曹晋其,蒋兴浩,孙铁锋.基于训练图 CNN 特征的视频人体动作识别算法[J].计算机工程,2017,43(11):234-238.
- [8] 辛义忠,邢志飞.基于 Kinect 的人体动作识别方法[J].计算机工程与设计,2016,37(4):1056-1061.
- [9] 李顺,郭星,吴建国.基于关键帧和骨骼信息的人体动作识别方法[J].传感器与微系统,2019,38(11):26-30.
- [10] 宋震.面向多 Kinect 的三维人体骨架提取及动作识别研究与应用[D].济南:山东大学,2020.
- [11] BAZAREVSKY V, GRISHCHENKO I, RAVEENDRAN K, et al. BlazePose: On-device real-time body pose tracking [J/OL]. *ArXiv E-prints*, 2020. <https://arxiv.org/abs/2006.10204>.
- [12] 赵书芳,汤汶,万韬阮,等.面向 Kinect 深度图像的导向滤波算法改进[J].单片机与嵌入式系统应用,2020,20(3):46-49,53.
- [13] 周凤余,尹建芹,杨阳,等.基于时序深度置信网络的在线人体动作识别[J].自动化学报,2016,42(7):1030-1039.
- [14] 吴艳春,孙红卫,尹建芹.基于线性回归分析的重重复作计数估计[J].济南大学学报(自然科学版),2019,33(6):496-499.
- [15] 毕京学,汪云甲,曹鸿基,等.一种波峰波谷检测的智能手机计步算法[J].中国惯性技术学报,2020,28(3):287-292.
- [16] 张恒鑫,叶颖诗,蔡贤资,等.基于人体关节点的高效动作识别算法[J].计算机工程与设计,2020,41(11):3168-3174.

作者简介

王威,在读硕士研究生,主要研究方向为智能检测技术。

E-mail:imww@mail.ustc.edu.cn

孙少明(通信作者),研究员,博士,主要研究方向为运动与健康。

E-mail:smsun@iim.ac.cn