

文章编号:1004-7220(2019)06-0644-06

基于特征融合的人体运动识别

连西静, 崔升

(复旦大学 航空航天系, 上海 200433)

摘要:目的 基于手机内置传感器所获得人体运动信号,建立人体运动识别模型,为身体状况评估、特殊人群监护以及其他生物医学研究提供支持。**方法** 使用手机内置传感器采集运动信号,并结合公共数据集 UCI HAR 和 WISDM 作为实验数据。采用卷积神经网络与自回归模型相结合的特征提取方式,建立人体运动识别模型。**结果** 模型在自采集数据、UCI HAR 和 WISDM 中均取得 90% 以上的识别正确率。**结论** 引入自回归模型,可以避免手工设计特征值的缺陷,并有效减少大规模堆积卷积层的计算量。研究结果证明,基于特征融合的方法可以有效识别人体运动。

关键词: 人体运动识别; 时间序列分类; 卷积神经网络; 自回归模型

中图分类号: R 318.01 **文献标志码:** A

DOI: 10.16156/j.1004-7220.2019.06.012

Human Activity Recognition Based on Features Fusion

LIAN Xijing, CUI Sheng

(Department of Aeronautics and Astronautics, Fudan University, Shanghai 200433, China)

Abstract: Objective To establish a human activity recognition (HAR) model based on human activity signals obtained by built-in sensors of the mobile phone, so as to support daily physical state assessment, special population monitoring and other biomedical researches. **Methods** The mobile signal was collected using the mobile phone built-in sensor, and the public data set UCI HAR and WISDM were used as experimental data. The HAR model was established by using the feature extraction method combined with convolutional neural network and autoregressive model. **Results** The models all achieved more than 90% recognition accuracy in the self-collected dataset, UCI HAR and WISDM. **Conclusions** The introduction of autoregressive model can avoid the manual design eigenvalues and effectively reduce the computational complexity of large-scale stacked convolutional layers. The research findings prove that the method based on feature fusion can effectively recognize human activity.

Key words: human activity recognition (HAR); time series classification; convolutional neural network; autoregressive model

人体运动识别 (human activity recognition, HAR) 广泛地应用于健康检测、安全防护、人机交互等生物医学研究领域。张峻霞等^[1]通过上、下楼梯步态参数变化特征研究,为助行器的设计提供数据支持。李宏恩等^[2]通过脚底压电信号检测人体是

否摔倒。HAR 还可以为日常锻炼提供决策依据。

通过数据判断人体正处于何种运动是一个典型的模型识别问题,通常分为数据采集、特征提取、分类器设计 3 个步骤。数据采集主要分为两大类:一类是通过摄像头采集图像与视频^[3-4],然而摄像

头安装在固定位置,易受背景的光线条件以及物体的遮挡影响;另一类是通过智能传感器采集数据,常用的智能传感器有加速度计、陀螺仪等。智能传感器的测量方式自由,广泛地存在于智能手机、智能手环、智能眼镜中。本文主要基于智能传感器采集的数据进行研究。

特征提取是从采集的原始数据中获取有效的特征值。传统提取常基于手工设计,例如 Anguita 等^[5]手工提取了 561 个特征用于运动识别,但 Huynh 等^[6]研究表明,不存在某个特定的特征在所有活动中都表现最佳。手工特征提取需要借助相应领域的专业知识,并以统计特征为主^[7]。早期关于 HAR 模型的研究多集中在寻找合适特征值来提高模型准确率方面。随着深度学习的发展,自动提取特征开始应用于 HAR 模型。史殿习等^[8]使用无监督特征学习方法提取特征值,采用支持向量机进行活动识别。吴军等^[9]采用深度学习方法,将传感器数据变换为类似于三通道的 RGB 图像格式作为输入值。Jiang 等^[10]采用多层卷积神经网络(convolutional neural network, CNN),将输入从多通道的信号转为图像以提高正确率。王忠民等^[11]使用 CNN 进行特征学习,结合决策树算法完成人体行为的识别。Ronao 等^[12]着重分析卷积尺度与层数的影响,使用快速傅立叶变换的信息提高准确率。

CNN 可以提取高度抽象特征,这些特征具有很好的平移不变性,但是需要大量的卷积层堆叠,以及大量数据作为训练。Ravi 等^[13]研究证明,在有限资源的设备上通过深度学习提取出的特征,可能效果不如一组完整定义的手工特征。对于时间序列建模,自回归(autoregressive, AR)模型是常用的模型。通过 AR 模型能够预测序列的发展趋势,其系数自然可以作为序列的特征进行模式识别。通过少量的卷积提取特征并结合 AR 模型,本文得到了一个高效且精准的模型,为 HAR 的实际应用提供解决方案。

1 模型

当人体运动处于某种稳定的形式时,运动信号是平稳时间序列,可使用 AR 模型进行分析。结合卷积提取的特征与 AR 系数,得到人体运动模式识别框架(见图 1)。首先把经过处理的原始数据作为

输入,将输入分别进行卷积特征提取与 AR 模型系数计算。然后将卷积提取的特征与 AR 模型系数共同作为神经网络的输入,进行人体活动的分类。

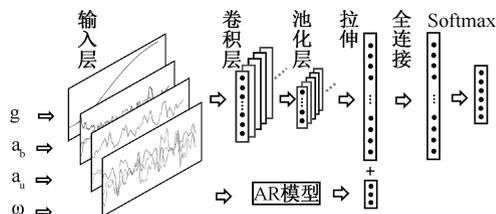


图1 人体运动模型识别框架

Fig.1 Architecture of the human activity recognition method

1.1 数据输入

手机内置多种传感器可用于 HAR。以三轴加速度计与陀螺仪采集的数据为例,数据采集使用的传感器及其采样频率不同,每一帧通常设定为 2.56~10.00 s。为了充分利用数据集,相邻两帧重合 50%。由于大部分人体运动频率较低,对每一帧原始数据采用 20 Hz 低通滤波器进行过滤。

过滤后数据为 6 个通道的信号,分别是 3 轴加速度信号 a_u 以及 3 轴角速度信号 ω [见图 2(a)、(b)]。传感器测量的加速度包含人体运动产生的加速度 a_b 与重力加速度 g 两部分。当人体处于 3 种静止状态时 $a_b=0$,测量的加速度仅为重力加速度,并且有 $g = \sqrt{g_x^2 + g_y^2 + g_z^2}$,其中 g_x 、 g_y 、 g_z 表示重力加速度在加速度计 x 、 y 、 z 三轴上的分量,其大小与加速度计在空间中的角度有关。3 种静态动作时人体的倾斜角不同,对应重力加速度各分量的值也不同[见图 2(a)]。

为了将人体运动加速度与重力加速度分离,通常认为重力加速度只包含在加速度信号低频分量中,并根据 Anguita 等^[5]工作确定 0.3 Hz 是最佳的分割频率。将 a_u 信号用 0.3 Hz 巴特沃斯低通滤波器进行滤波,得到重力加速度信号 g 。将 a_u 信号用 0.3 Hz 巴特沃斯高通滤波器进行滤波,得到人体运动加速度信号 a_b 。则得到三轴加速度信号 a_u 、三轴角速度信号 ω 、三轴人体运动加速度信号 a_b 与三轴重力加速度信号 g 共 12 个通道的信号。为了在卷积时充分挖掘信号之间的关联性,将信号排列为图 1 中 $[f_1, 3, 4]$ 的三维矩阵,使用二维卷积核处理,

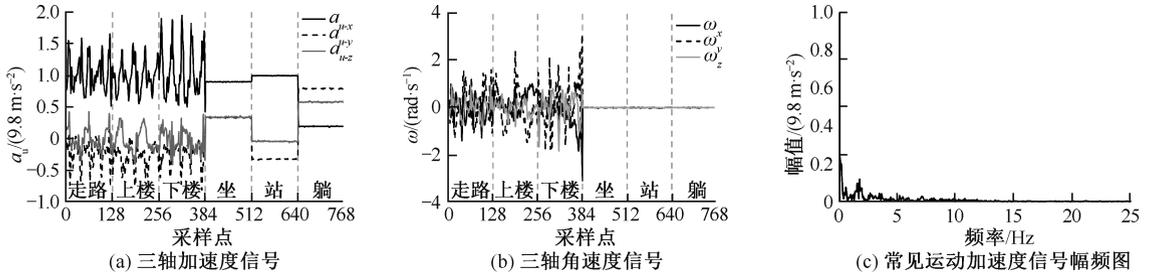


图2 人体运动数据分析

Fig.2 Data analysis of human activity (a) Triaxial acceleration signals, (b) Triaxial angular speed signals, (c) Amplitude-frequency diagram of common activity acceleration signals

其中 f_1 表示每一帧的长度, 3 表示 x, y, z 三轴的数据, 4 表示有 4 层的数据通道。由图 2(c) 人体常见运动加速度信号的幅频可知, 人体运动的频率基本都在 10 Hz 以内。

1.2 卷积神经网络

CNN 由自动特征提取器与神经网络组成, 它通过堆叠多重卷积运算产生更多抽象特征, 而参数共享和局部感知大幅度地降低待参数数目, 有效防止过拟合。卷积部分主要分为卷积层与池化层。

卷积层: 卷积层的输入是 12 个通道的信号, 按照 $[f_1, 3, 4]$ 的方式排列。输出层中每个节点的输入只是上一层的局部块, 可以对输入的每小块做更深入分析, 取得抽象程度更高的特征。卷积核的形状为 $[k_w, k_h, 4]$, 由 $\text{Convolut} = \text{input} \times \text{kernel}$ 得到:

$$x_c(l, m, \sigma) = \sum_{k=1}^4 \sum_{j=1}^{k_h} \sum_{i=1}^{k_w} x(l-i, m-j, k) \times h_\sigma(i, j, k) \quad (1)$$

式中: x 为输入的数据; x_c 表示卷积层的输出; h_σ 为卷积核; $l = 1, 2, \dots, f_1$ 且 $m = 1, 2, 3$; $\sigma = 1, 2, \dots, n_l$, n_l 表示卷积的层数, 通过增加卷积层数可以获得大量特征。

池化层: 通过池化缩小矩阵尺度, 加快计算速度, 同时有效地控制过拟合。选择过滤器的尺寸为 $[k_l, 1, 1]$, 采用最大值池化, 池化后的结果为:

$$x_p(i, m, \sigma) = \max \{ x_c[i \cdot k_l + 1 \sim (i+1) \cdot k_l + 1, m, \sigma] \} \quad (2)$$

$$i = 0, 1, \dots, f_1/k_l$$

式中: x_p 表示池化层的输出, 且池化过滤器的移动步长为 k_l 。

1.3 自回归模型

AR 模型的输入为三轴加速度信号 a_u 以及三

轴角速度信号 ω , 共 6 个通道的信号。对于每个通道:

$$x(n) = \sum_{i=1}^p \alpha(i)x(n-i) + \varepsilon(n) \quad (3)$$

式中: $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_p)^T$ 为 AR 模型的系数; p 代表阶数; $\varepsilon(n)$ 为误差项。

1.3.1 AR 模型系数求解 使用 Burg 算法^[14], 使得参数 α 的求解令序列 $x(n)$ 的前后向预测误差功率之和最小, 即:

$$P_p^{\text{nb}} = \frac{1}{N-p} \sum_{n=p}^{N-1} \{ |\varepsilon_p^{\text{f}}(n)|^2 + |\varepsilon_p^{\text{b}}(n)|^2 \} \quad (4)$$

式中: N 表示序列的长度, 上标 f 表示向前预测, b 表示向后预测。当阶次由 1 增至 p 时, $\varepsilon_p^{\text{f}}(n)$ 与 $\varepsilon_p^{\text{b}}(n)$ 的递推关系如下:

$$\left. \begin{aligned} \varepsilon_m^{\text{f}}(n) &= \varepsilon_{m-1}^{\text{f}}(n) + k_m \varepsilon_{m-1}^{\text{b}}(n-1) \\ \varepsilon_m^{\text{b}}(n) &= \varepsilon_{m-1}^{\text{b}}(n-1) + k_m \varepsilon_{m-1}^{\text{f}}(n) \\ m &= 1, 2, \dots, p \\ \varepsilon_0^{\text{f}}(n) &= \varepsilon_0^{\text{b}}(n) = x(n) \end{aligned} \right\} \quad (5)$$

将式(5)代入式(4), 得到 P_p^{nb} 仅是 k_m 的函数, 令 $\partial P_p^{\text{nb}} / \partial k_m = 0$, 使得 P_p^{nb} 最小的 \hat{k}_m 为:

$$\hat{k}_m = \frac{2 \sum_{n=m}^{N-1} \varepsilon_{m-1}^{\text{f}}(n) \varepsilon_{m-1}^{\text{b}}(n-1)}{\sum_{n=m}^{N-1} |\varepsilon_{m-1}^{\text{f}}(n)|^2 + \sum_{n=m}^{N-1} |\varepsilon_{m-1}^{\text{b}}(n-1)|^2} \quad (6)$$

式中: $m = 1, 2, \dots, p$ 。

使用 Levinson 算法递推求出:

$$\left. \begin{aligned} \hat{\alpha}_m(k) &= \hat{\alpha}_{m-1}(k) + \hat{k}_m \hat{\alpha}_{m-1}(m-k) \\ \hat{\alpha}_m(m) &= \hat{k}_m \\ \hat{P}_m^{\text{nb}} &= \hat{P}_{m-1}^{\text{nb}} (1 - |\hat{k}_m|^2) \end{aligned} \right\} \quad (7)$$

1.3.2 AR 模型定阶 AR 模型常用阶数确定方法

有最小信息量准则与最小预测误差准则等。但是以上准则大多是从信号拟合的程度去考虑,更为重要的是,它会使得不同样本得到的阶数有差异,故采用降频率搜索的方法。在确定搜索范围时,过高的采样频率会造成计算上的复杂,同时会降低拟合度。

使用 AR 模型时,对高采样频率的样本进行降采样处理,令降采样因子为 M 。为了使得降采样之后的信号不发生混叠,由采样定理 $f_s \geq 2f_{\max}$, f_s 为实际采样频率, f_{\max} 为信号包含的最高频率。又因人体运动一般低于 10 Hz,得到 $f_{\max} = 10$, 于是有:

$$\left. \begin{aligned} f_0/M &\geq 2f_{\max} = 20 \\ M &\leq f_0/20 \end{aligned} \right\} \quad (8)$$

式中: f_0 为原序列的采样频率。由于通常 P 小于序列长度的 $1/3$,为了尽可能找到最好的特征,在如下空间中进行搜索:

$$\left. \begin{aligned} M &\in [1, f_0/20] \\ P &\in [1, f_1/3] \end{aligned} \right\} \quad (9)$$

将得到的 AR 系数作为特征值,使用随机森林法进行训练与测试,寻找出 M 和 P 的最优值。

1.4 神经网络分类模型

使用全连接的神经网络作为分类器,经过卷积和池化处理后,原始数据的信息已经被转化成特征量。将这些特征量与 AR 模型的系数结合作为输入,使用全连接层连接来完成动作分类。最后一层为 Softmax,通过计算概率分布来获取分类结果。

$$Y = \text{Softmax}(W_f \cdot [\hat{x}_p, \alpha] + b) \quad (10)$$

$$\text{Softmax}(y)_i = y'_i = \frac{e^{y_i}}{\sum_{j=1}^k e^{y_j}} \quad (11)$$

式中: Softmax 为归一化指数函数; W_f, b 表示全连接层的系数。 \hat{x}_p 是将三维向量 x_p 重新排列后得到的一维向量, Softmax 的计算过程可见式(11), k 为运动类型数。最终得到 Y 为 k 种运动类型的概率响应,是一个一维向量,各个分量分布在 $0 \sim 1$ 之间,分量总和为 1,即 Softmax 层的输出就是输入量分类到各个类别的概率,取最大概率对应的类别作为模式识别的结果。

1.5 模型训练

模型训练采用 Tensorflow 框架,其中在卷积层,池化层与全连接层后都用非线性激活函数 ReLU。

使用 ReLU 收敛速度会比 sigmoid 与 tanh 快很多,这在 Ignatov^[15]的工作中得到证明。在全连接层中引入 Dropout,随机地使某些节点失活,提升模型的泛化能力。同时使用 L2 正则化,限制权重的大小,使得模型不能随意拟合训练数据中的噪音。

2 实验结果与分析讨论

2.1 自采集数据

为了验证模型的有效性与可靠性,设计实验采集数据,采集人体不同运动的加速度与角速度数据。运动分为 3 种,分别为步行、上楼、下楼。实验参与者为 5 男 4 女,年龄 20~30 岁。数据由同一部 iphone 7 采集,采集软件为 Matlab 7.0。由于设备与软件限制,实际采样频率为 100 Hz。为降低后期计算,将采集到的原始数据降采样,使得采样频率为 50 Hz。手机通过腰包放置在志愿者腰部左前方,人体站立时传感器 x 轴垂直地面向下。每位志愿者都分别进行步行 3~5 min 以及上 6 层楼梯、下 6 层楼梯的运动。可以通过视频同步记录人体的多种运动切换,实验结束后根据视频为采集数据添加标签。为了减少后期工作,不使用视频同步记录,每次实验只采集单个动作,并用动作名称命名采集到的数据。每个动作采集 2~4 次。除手机需要固定位置放置,动作采集需持续进行之外,该数据采集过程对志愿者没有任何约束。

2.2 公共数据集

为验证模型在各种人体活动识别任务中的适用性与泛化能力,在实验数据中增加两个常用的公共数据集 UCI HAR^[5]与 WISDM^[16]。它们分别将手机放置在腰部与口袋中进行测量,表 1 是对它们的简要描述,其中 A 表示加速度计, G 表示陀螺仪。

表 1 数据集总结

Tab.1 Data collection

数据库	使用传感器	采集人数	运动种类	训练样本量	测试样本量	采样频率/Hz
UCI HAR	A, G	30	6	7 352	2 947	50
WISDM	A	36	6	7 367	3 036	20
自采集数据	A, G	9	3	4 633	2 803	50

UCI HAR 数据集使用手机内置的加速度计与陀螺仪进行数据采集,采集对象为 30 位 19~48 岁志愿者。在实验室条件下将智能手机固定在腰部,

执行6项动作,即行走、上楼梯、下楼梯、坐下、站立、躺下。其有一个规范的测试集,每一帧数长度为2.56 s,可以方便地比较不同工作的效果,故被广泛地用于研究。

WISDM数据集使用手机内置的加速度计在实验室条件下采集36位志愿者的数据。将智能手机放于口袋中,执行6项动作,即走路、慢跑、坐下、站立、上楼、下楼。按照10 s每帧来划分数据。

为了更好地证明模型的鲁棒性以及已与有工作进行公平比较,UCI HAR使用标准的训练集与测试集并根据Ignatov^[15]的研究结果,对UCI HAR的数据进行减均值预处理。WISDM采集人数较多,将1~26位志愿者的数据作为训练集,剩余数据作为

测试集。本文所建数据库任取3人(编号为1,5,9)数据作为测试集,其余为训练集。

2.3 计算结果

首先通过搜索求得最佳AR系数。UCI HAR识别率最高出现在 $M=3, P=5$ 时;WISDM识别率最高出现在 $M=1, P=21$ 时;自采集数据集识别率最高出现在 $M=3, P=10$ 时。随着 M 增大,识别正确率将会有所提升,说明适当降低采样频率,得到的AR模型系数更有利于模式识别。随着 P 增加,识别正确率先提升后降低。对比发现,自采集数据搜索结果具有更大的波动,主要原因是其采集的人数相对其他两个数据集较少,使得数据集对参数更加敏感(见图3)。

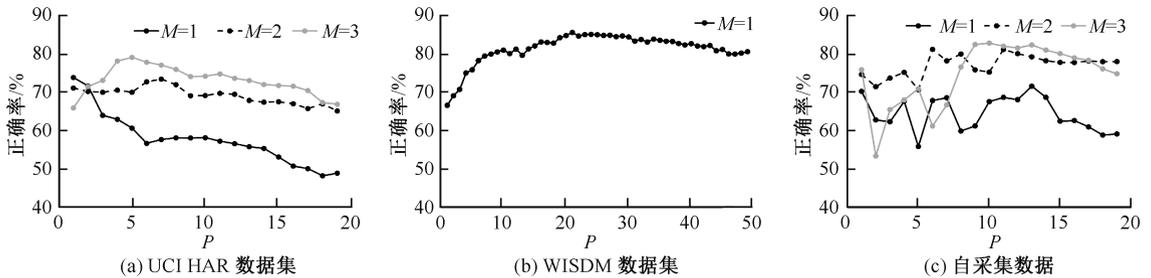


图3 不同数据集的最佳AR参数搜索

Fig.3 Optimal AR parameter search for different dataset (a) UCI HAR dataset, (b) WISDM dataset, (c) Dataset in this study

深度神经网络没有很好的超参数选择方法,通过大量实验,将卷积核尺寸设置为 $[18, 3, 4]$,卷积层数 $n_1=30$,池化过滤器尺寸为 $[5, 1, 1]$,全连接层的节点数 $n_f=1300$,全连接层激活节点的比例 $r=0.1$ 。将模型分别应用于3个数据集上。测试结果如表2所示。

表2 提出框架在不同数据集上的识别效果

Tab.2 Recognition effect of the proposed framework on different data sets

运动	UCI HAR		WISDM		本文	
	精确率/%	召回率/%	精确率/%	召回率/%	精确率/%	召回率/%
走路	99.60	99.80	96.75	96.97	99.86	91.38
上楼	99.16	99.79	94.58	82.63	99.69	99.53
下楼	99.52	99.05	89.39	96.97	80.93	100.00
坐	95.74	91.45	85.88	71.57	—	—
站	92.57	96.05	83.63	84.84	—	—
躺	100.00	100.00	—	—	—	—
慢跑	—	—	93.93	98.25	—	—
加权平均值	97.68	97.66	92.80	92.89	95.92	95.01

2.4 结果讨论

由表2可以看出,本文建立的人体识别框架在3个数据集上正确率均达90%以上。其中,动态动作识别相对较为准确,静态动作识别准确率较低。这是因为在坐与站立状态时,人体动作很微小。主要依靠重力加速度在传感器3个轴上的分量来判断手机在空间中的相对角度,并以此来进行分类。但由于坐与站立状态时人体倾斜角度不固定,没有明显分界线,故识别准确率较低。UCI HAR与WISDM数据集采集的人数与动作基本相同,主要区别在于手机放置的位置。放置腰部识别正确率可高达97.66%,考虑到手机放置于口袋中是现代生活常见的携带方式,WISDM的识别准确率92.73%对实际应用更有指导意义。

为了验证CNN+AR模型是否比仅使用CNN或AR模型更有优越性,将数据集依次在3种模型上进行测试,运行结果如图4所示。3个数据集呈现出相同的结果:CNN+AR效果最好,其次是CNN。对于

UCI HAR 数据集, CNN 模型已经取得了较高的正确率, 加入 AR 模型后, 识别准确率有小幅提升。

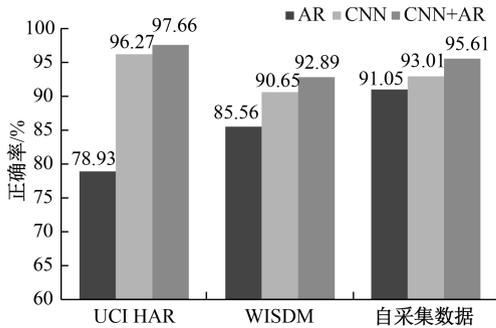


图 4 不同模型识别正确率对比

Fig. 4 Comparison of recognition accuracy among different models

为了证明所提出方法的优越性, 将本文方法的计算结果与已有的工作进行对比(见表 3)。使用深度学习进行特征提取并不是总优于手工设计特征。在 UCI HAR 数据集上使用手工特征提取可使得正确率达到 96.37%, 但文献[17]中使用了 CNN 正确率为 94.79%。本文提出的方法在识别正确率上仅低于文献[15]中的结果, 但文献[15]使用了 198 层的卷积, 本文仅使用了 30 层卷积。为了比较计算量, 在 4 核 Intel core i5-7300HQ CPU 与 NVIDIA GTX 1050Ti 4 GB GPU 上对模型进行测试, 使用文献[15]中的模型, 每秒钟可以计算出 2 628 个样本的结果, 而本文方法可以计算出 3 480 个样本的结果, 证明本模型计算量要小于文献[15]中的计算量。由于未使用手工设计特征, 故本文方法更具有通用性。同时, 计算时间消耗远小于文献[15]。数据样本长度为 2.56~10.00 s, 故实际应用中可实现实时的运动识别。

表 3 本文提出框架与已有工作对比

Tab.3 Comparison of the proposed framework with existing work

数据集	参考文献	方法	正确率/%
UCI HAR	[17]	卷积神经网络	94.79
	[10]	信号转为图像+卷积神经网络	95.18
	[7]	手工特征提取+支持向量机	96.37
	本文	卷积神经网络+自回归模型	97.66
WISDM	[16]	逻辑回归	78.10
	[16]	多层感知器	91.70
	本文	卷积神经网络+自回归模型	92.89
自采集数据	[15]	手工特征提取+卷积神经网络	93.32
	本文	卷积神经网络+自回归模型	95.61

3 结语

为了对人体的运动进行监护, 本文提出一种结合了 CNN 与 AR 模型的人体活动识别框架, 避免了手工设计特征的局限性。在自采集数据、UCI HAR、WISDM 正确率分别达到了 95.61%、93.32% 与 97.66%。该结果证明, CNN 与 AR 模型提取的特征可以有效互补, 并且相对于只使用 CNN 模型减少了计算量, 使得计算效率提升 32.42%。HAR 分类常基于低功耗设备, 例如智能手机与智能手环, 故降低模型计算量有着重要意义。HAR 模型可以提供每天运动量的建议, 提醒用户避免久坐, 以及在老人摔倒时及时报警。若要对人体运动状态进行更深入建模, 可以使用光电透射测量脉搏信号, 结合人体内部信息, 更准确地评估人体状态。

参考文献:

- [1] 张峻霞, 窦树斐, 苏海龙, 等. 上、下楼梯步态参数变化特征研究[J]. 医用生物力学, 2016, 31(3): 266-271.
ZHANG JX, DOU SF, SU HL, et al. Variation characteristics of gait parameters during stair ascent and descent [J], J Med Biomech, 2016, 31(3): 266-271.
- [2] 李宏恩, 鲍申杰, 高晓航. 压电式步态分析系统在足底压力监测中的应用[J]. 医用生物力学, 2017, 32(3): 288-292.
LI HE, BAO SJ, GAO XH. The application of piezoelectric gait analysis system in plantar pressure monitoring [J]. J Med Biomech, 2017, 32(3): 288-292.
- [3] POPPE R. A survey on vision-based human action recognition [J]. Image Vision Comput, 2010, 28(6): 976-990.
- [4] 黄凯奇, 陈晓棠, 康晓锋, 等. 智能视频监控技术综述[J]. 计算机学报, 2015, 20(6): 1093-1118.
- [5] ANGUIA D, GHIO A, ONETO L, et al. A public domain dataset for human activity recognition using smartphones [C]//Proceedings of 20st European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning. Bruges: ESANN, 2013: 437-442.
- [6] HUYNH T, SCHIELE B. Analyzing features for activity recognition [C]//Proceedings of the 2005 Joint Conference on Smart Objects and Ambient Intelligence: Innovative Context-Aware Services, Usages and Technologies. Grenoble: ACM, 2005: 159-163.
- [7] ANGUIA D, GHIO A, ONETO L, et al. Human activity recognition on smartphones using a multiclass hardware-friendly support vector machine [C]//Proceedings of