

# 基于卷积神经网络的活动识别分析系统及应用

靳旭玲<sup>1</sup>, 许文锐<sup>1</sup>, 张 晖<sup>2</sup>, 孙思清<sup>2</sup>, 周 恒<sup>2</sup>, 刘 浩<sup>1</sup>, 刘金鑫<sup>1</sup>, 冯建勇<sup>3</sup>

<sup>1</sup>北京建筑大学, 北京

<sup>2</sup>浪潮集团有限公司, 山东 济南

<sup>3</sup>中国科学院计算技术研究所, 北京

Email: [jye@ict.ac.cn](mailto:jye@ict.ac.cn)

收稿日期: 2020年9月9日; 录用日期: 2020年9月21日; 发布日期: 2020年9月28日

---

## 摘 要

活动识别技术在智能家居、运动评估和社交等领域得到广泛应用。本文设计了一种基于卷积神经网络的活动识别分析与应用系统, 通过分析基于Android搭建的前端采集的三向加速度传感器数据, 对用户的当前活动进行识别。实验表明活动识别准确率满足了应用需求。本文基于识别的活动进行卡路里消耗计算, 根据用户具体的活动、时间以及体重计算出相应活动在相应时间内具体消耗的卡路里消耗, 有助于建立健康生活模式。

## 关键词

活动识别, 卷积神经网络, 卡路里消耗

---

# Activity Recognition Analysis System and Application Based on Convolutional Neural Network

Xuling Jin<sup>1</sup>, Wenrui Xu<sup>1</sup>, Hui Zhang<sup>2</sup>, Siqing Sun<sup>2</sup>, Heng Zhou<sup>2</sup>, Hao Liu<sup>1</sup>, Jinxin Liu<sup>1</sup>, Jianyong Feng<sup>3</sup>

<sup>1</sup>Beijing University of Civil Engineering and Architecture, Beijing

<sup>2</sup>Inspur Group Ltd., Jinan Shandong

<sup>3</sup>Institute of Computing Technology, Chinese Academy of Sciences, Beijing

Email: [jye@ict.ac.cn](mailto:jye@ict.ac.cn)

Received: Sep. 9<sup>th</sup>, 2020; accepted: Sep. 21<sup>st</sup>, 2020; published: Sep. 28<sup>th</sup>, 2020

**文章引用:** 靳旭玲, 许文锐, 张晖, 孙思清, 周恒, 刘浩, 刘金鑫, 冯建勇. 基于卷积神经网络的活动识别分析系统及应用[J]. 计算机科学与应用, 2020, 10(9): 1690-1697. DOI: [10.12677/csa.2020.109179](https://doi.org/10.12677/csa.2020.109179)

## Abstract

Activity recognition technology has got widely used in smart home, sports assessment, social contact and other fields. This paper designs an activity recognition analysis and application system based on convolution neural network. By analyzing the data of three-way accelerometer collected in Android devices, the current activities of a user are identified. Experiments show that the accuracy of activity recognition meets the requirement of application. This paper calculates calorie expenditure based on identified activities, and calculates calorie expenditure based on a user's specific activities according to time and weight for the corresponding activities in the corresponding time, which helps to establish a healthy lifestyle.

## Keywords

Activity Recognition, Convolutional Neural Networks, Calorie Consumption

Copyright © 2020 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

用户行为识别[1]与理解是以人为中心的普适计算领域的重要研究内容之一，也是现今社会智慧化、个性化、移动端服务化的关键点。如何了解并实现用户行为识别显得极其重要。传统的行为识别通常是类似于用户的跑步，行走，站立与上下楼这样简单活动。而随着科技进步的飞速发展，如何识别用户行为与社交方面也有了重大的突破，复杂的用户行为场景也提供了复杂的行为识别，而如何再次获取这些复杂的行为就显得尤为重要。

借助于手机的加速度传感器[2]检测喝酒的人的行走的步态情况，来推测其喝酒的程度。使用环境传感器、物体传感器[3]，例如 RFID 标签与生活中常用物品结合，对智能家庭中日常活动识别进行研究。活动识别不仅包括识别用户的活动，通过智能设备对用户的生活方式进行识别也是一种研究方向。如文献[4]利用获取手机的蓝牙信号来推测用户的日常交流信息。文献[5]描述了一个自动评分系统，主要是针对用户在手机和平板上看电影时产生的使用习惯可以被用来捕捉到一个广泛的范围。

活动识别应用于医疗领域也是一种发展趋势，因为疾病问题会使得身体的运动或功能发生变化，因此可以通过使用相应的传感器进行检测。文献[6]中通过穿戴式传感器附加到人的鞋子上来反映人行走的速度与步态，对患有帕金森综合征的人的身体情况进行了研究。通过获取阵发性心房颤动疾病人的心电图数据，对发病前的状态进行预测[7]。文献[8]使用 RFID 标签技术，在急救中，观察患者的身体反应或病情征兆，来辅助急救人员进行相应的治疗措施。文献[9]主要评估了一个基于智能手机的活动识别分类器在监测健康人和中风患者时的表现。文献[10]主要评估了一个基于智能手机的活动识别分类器在监测健康人和中风患者时的表现。方法就是让参与者佩戴智能手机，并进行日常行为活动，然后将采集到的数据分成五个特征用来区分参与者的行为，并且通过计算敏感性、特异性来评估 HAR 分类器的表现。文献[11]这篇文章主要介绍了通过家庭监测设备提供到智能手机上的信息监测重点病患，主要是用了一个决策树框架的集合来训练和预测多类人体活动系统。

本文主要的工作为：设计 Android 端的 UI 界面，提供给用户可操作的 APP。用户通过 APP 进行注册登录，登陆后填写用户的个人信息，并且记录相关的活动行为数据。通过与服务器数据库的连接，将用户的个人信息，类似于身高体重加上活动行为数据一起保存在数据库中。通过活动识别算法网络的分析计算，得出用户的活动标签，即用户的具体行为，用户同样可以查看用户活动消耗卡路里情况，向服务器发送请求，对活动信息进行相应的卡路里转化返回到客户端，并以图表的形式展示出来，方便客户的查看。

## 2. 活动识别系统

### 2.1. 活动识别的系统架构

活动识别系统整体可分为 Android 应用、云服务器、两个部分。Android 应用主要负责与用户的信息交互，通过云服务器提供的接口运行服务器相应的功能。云服务器主要负责对 Android 端传递过来的用户操作的需求进行分析处理，解析对应的 URLs，运行相应的处理方法，同时将处理的结果返回给 Android 端。

基于以上介绍，本系统将对用户的活动信息进行上传，服务器对 Android 端上传的信息进行活动识别，并可以根据用户需求，将对应活动转化为卡路里消耗传回给 Android 端，并进行可视化，系统总体设计架构如图 1 所示。

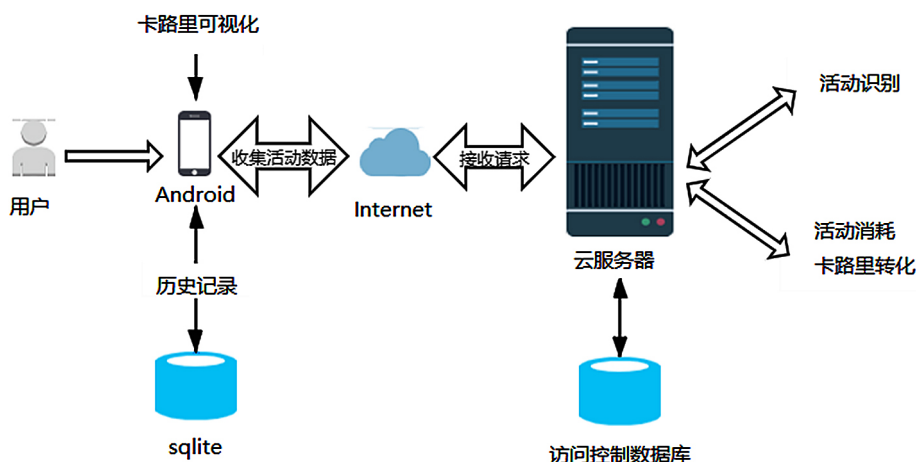


Figure 1. System network framework  
图 1. 系统网络架构图

### 2.2. 活动识别的通信框架

用用户可通过 Android 应用注册用户信息，包括用户名密码传递到服务器，服务器对用户名信息进行查重处理，不相同则保存到数据库，相同则驳回请求；用户可登陆向服务器发送请求，服务器校验该登陆用户名密码是否与数据端相同，相同则登陆成功，不相同则驳回请求。登陆后，用户完善自己信息传递到服务器中，服务器操作保存到数据端。并开始记录用户的活动信息(包括活动信息，x, y, z 三轴加速度，起止时间)，并将活动信息传递给服务器，服务器进行相应的操作，对活动信息进行活动识别并保存到数据库中。用户还可以查询活动信息，向服务器发送请求，服务器会将活动信息从数据端取出来，并将其转化为卡路里消耗返回到 Android 端，进行可视化操作。具体操作如图 2 所示。

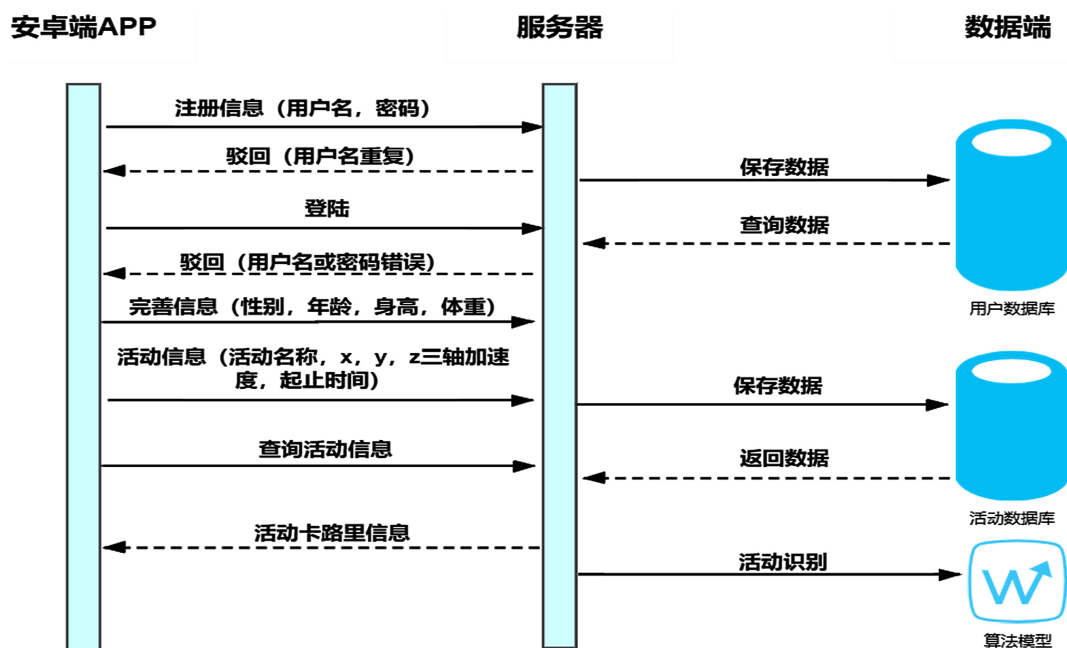


Figure 2. Message communication framework  
图 2. 消息通信结构图

### 3. 活动识别算法设计

卷积神经网络模型(简称 CNN)是一种深度神经网络, 它被开发用于图像数据, 例如, 如手写识别。事实证明, 经过大规模培训他们在挑战计算机视觉问题时非常有效, 例如识别和定位图像中的对象以及自动描述图像内容。它们是由两种主要类型的元素组成的模型: 卷积层和池化层。

图 3 提供了基于卷积神经网络的活动识别算法。该算法将由第一卷积层, 最大池化和第二卷积层组成。之后是算法的全连接层, 该层连接到 Softmax 层。

第一层卷积层 conv1, 输入的是  $1 \times 100$ , 3 通道数的数据, 也就是一组 100 条的三向加速度传感器数据, 卷积核大小设为  $1 \times 10$ , 3 通道, 共 60 个。步长为 1。偏差量的默认值设为 0.0。本文采用了 SAME 方式来进行 padding 操作, 一是为了保持输出的大小始终为  $1 \times 100$ , 二是为了防止边缘值的丢失。共输出 60 张特征图, 即输出  $1 \times 100$ , 3 通道。最后对输出的特征图进行 ReLU 的激活。

第二层池化层 pool1, 将第一层输出的 60 张特征图输入进去, 进行最大池化操作。通过一个  $1 \times 20$  的池化窗口进行池化, 在相邻的  $1 \times 20$  个像素值中选取最大值作为池化的输出值, 步长为 2。同样是采用 SAME 方法做 padding, 得到了新的特征图。特征图的个数不变, 为 60 个。

第三层卷积层 conv2, 将最大池化后的 60 张特征图输入, 采用的卷积核大小为  $1 \times 6$ 。输入的通道数为 60, 卷积核的个数为 10, 步长依旧设为 1。偏差值的默认值设为 0.0。10 个  $1 \times 6$  的卷积核构成一个卷积核组, 这个卷积核组与输入的 60 张特征图进行卷积操作, 输出 10 张新的特征图。然后对输出的特征图进行 ReLU 的激活。

第四层全连接层 fc1, 将卷积层 conv2 的输出列表化, 用于全连接层输入。定义的全连接层中有 1000 个神经元。为了防止数据规模小造成的过度拟合, 本文使用了 dropout 函数。CNN 训练过程中使用 dropout 是在每次训练过程中随机将部分神经元的权重置为 0, 即让一些神经元失效, 这样可以缩减参数量, 避免过拟合。dropout 率的选择: 经过交叉验证, 隐含节点 dropout 率等于 0.5 的时候效果最好, 原因是 0.5 的时候 dropout 随机生成的网络结构最多。

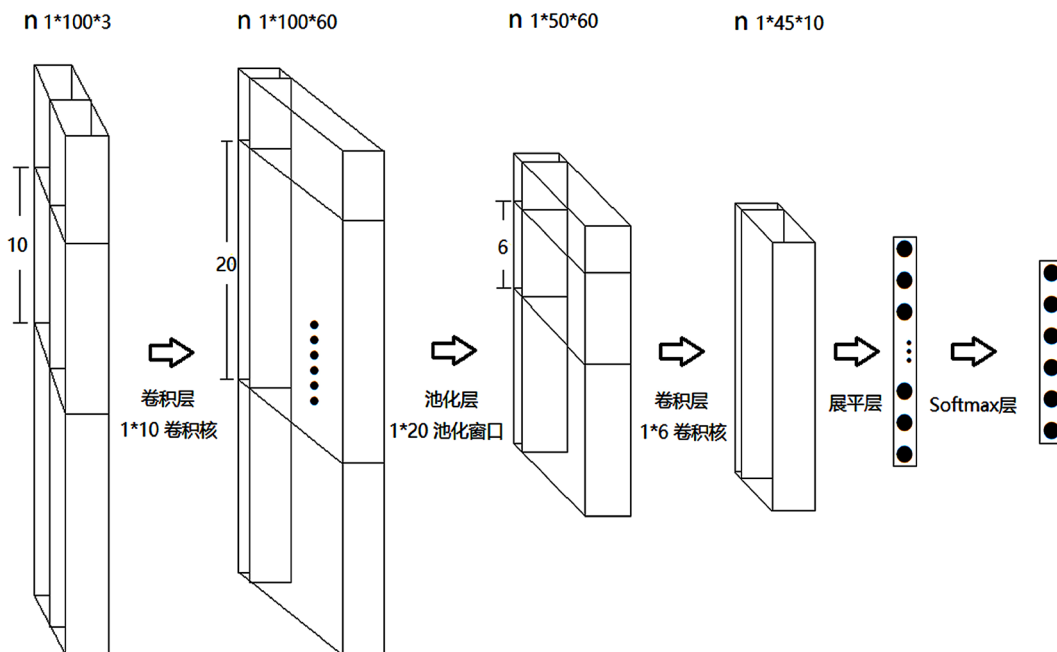


Figure 3. CNN model framework  
图 3. CNN 模型架构

第五层是全连接层 fc2，定义了 SoftMax 函数。它用于分类过程，将多个神经元的输出，映射到(0,1)区间内，因为有 6 种活动标签，故输出 6 个值，而这些值的和为 1。

## 4. 算法的实验过程与准确率分析

### 4.1. 实验过程

分采集到的数据来源约由 30 个人组成，每个人会做 6 个动作。这 6 个动作分别是 Walking, Jogging, Upstairs, Downstairs, Sitting, Standing。然后数据的选取就是在做动作的整个时间段里，按照一定采样频率对被测试人进行采样，从而得出了整体数据。

本文抽取的数据选取 20 个人作为训练集，选取 2 个人为测试集，然后每个人的每个动作抽取连续的 500 条数据，那么一个人就应该是  $500 \times 6$  条数据，那么训练集的大小就是  $500 \times 6 \times 20$  条数据。每组数据 100 个加速度传感器信息是一个不错的选择，为了符合输入格式，将其变为三维数组，大小为  $1 \times 100 \times 3$ 。此时  $1 \times 100$  就是图片格式的长  $\times$  宽，3 是通道数，本文的数据集中有 600 条这样的输入。其中 500 条作为训练集，100 条作为测试集。

### 4.2. 准确率分析

将 500 条训练样本输入算法从而训练出模型，这里输出了模型训练过程中的精确度，以及测试的准确度，最终达到了 83%。如图 4。

从下面的图 5 可以看到损失函数 loss 的值正在随训练呈现减小的趋势，最后在大约第 350 个训练样本时趋于稳定，并且数值无线趋近于 0。loss 函数是检验一个卷积神经网络是否可用的标准之一。loss 函数图像如果不是呈下降趋势则说明网络中的参数需要做进一步调整，而如果是呈下降趋势但是最终趋于稳定后的数值较大，则可能是网络的卷积层数不够。而如果 loss 图像过早的趋于 0，则可能是数据集的体量不足，导致了模型的过度拟合。

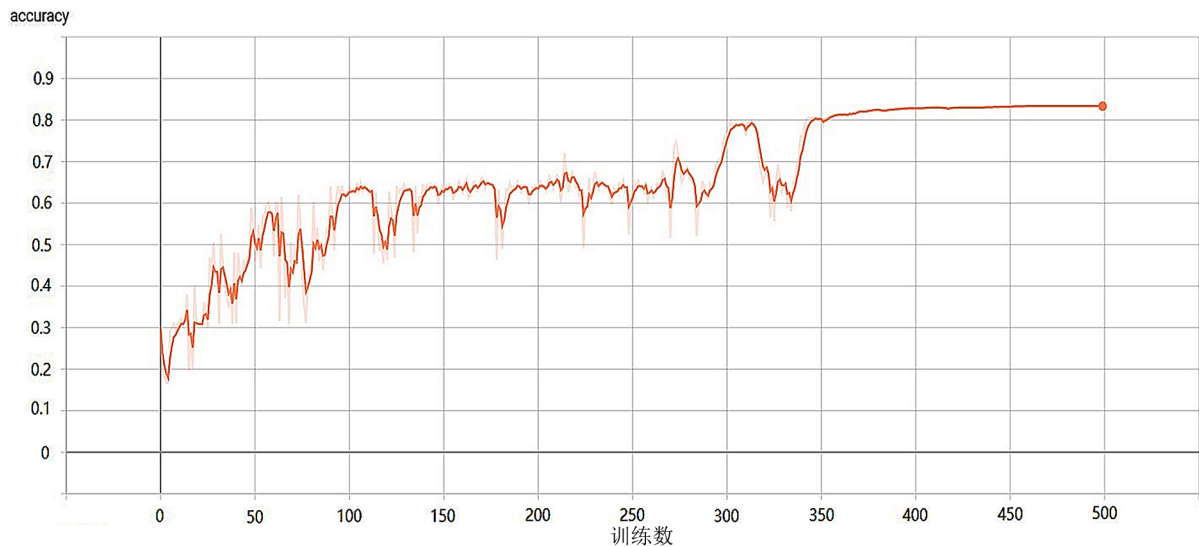


Figure 4. Line chart of model accuracy changing with training

图 4. 模型准确度随训练变化的折线图

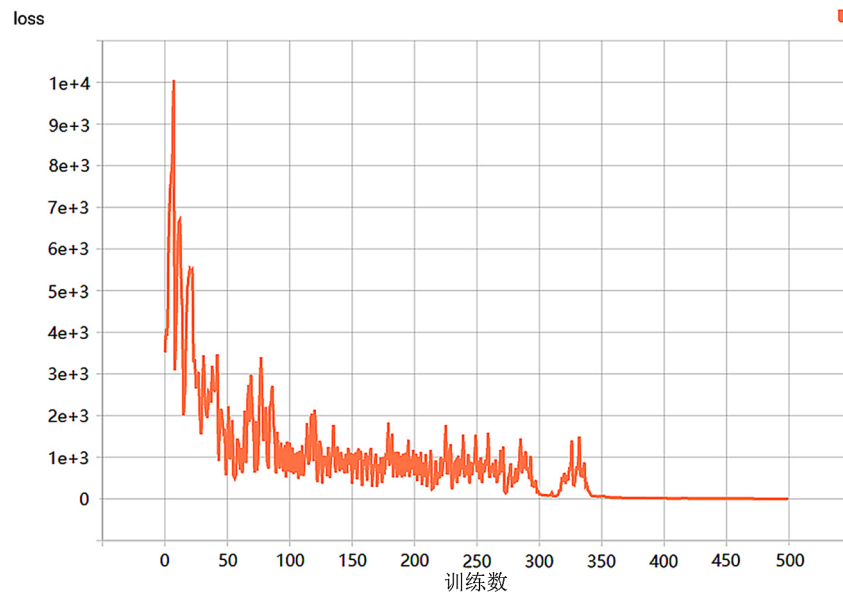


Figure 5. Line chart of loss function

图 5. 损失函数 loss 折线图

卷积神经网络已经搭建完成，由两个卷积层一个池化层两个全连接层构成。由于数据集的规模只有 500 个  $1 \times 100 \times 3$  的加速传感器数据，过多的卷积次数可能会导致过度拟合。搭建神经网络的难点不在于内容的编写，而在于对参数的调试。在经过对卷积核尺寸，卷积核深度不断的多次的调试最终使得模型的准确率达到 83%。接着把模型保存下来就可以应用了。

## 5. 基于活动识别的活动评估

用户可以通过本系统的 Android 应用登录账号进行记录用户一天的活动信息，包括三轴加速度值，时间。Android 端会将这些信息传输到服务器中，服务器对这些信息进行活动识别，并将结果保存到数据端，供用户进行进一步的查询。根据用户的需求，服务器对已识别的活动信息进行卡路里消耗转化，根




据用户具体的活动、时间以及体重计算出相应活动在相应时间内具体消耗的卡路里消耗，以体重小时为基准的日常活动强度系数如表 1 所示。具体公式如下所示。

$$\text{活动卡路里消耗(kcal)} = \text{体重(kg)} \times \text{活动时间(h)} \times \text{活动系数(kcal/h/kgBW)}$$

**Table 1.** Activity coefficient table  
**表 1.** 活动系数表

活动名称	活动系数(kcal/h/kgBW)
坐	1.9
站	2.1
走	2.4
跑	7.8
上楼	7.8
下楼	5.0

并根据时间，除了具体活动的消耗量，每天的活动消耗还加上人体基础代谢需要消耗的卡路里热量，使用户可以更准确的查询到每天，每月，每年的卡路里消耗量，并以折线图，柱状图的形式展示给用户，如图 6 所示，该图就是查询当天中用户具体活动占整体活动的消耗情况，可以在饼状图中清晰地看到每个活动具体的占比，使用户对自己的能量消耗有一个清晰地了解。



**Figure 6.** Activity consumption  
**图 6.** 活动消耗图

## 6. 总结与展望

为了提高人类的生活水平，与出于对人类健康的考虑，我们需要通过多源感知技术的活动识别分析

来对人类的行为进行研究。本文提出了一种基于卷积神经网络的活动识别方法。通过用户的行为采集数据，记录下行为数据后，用搭建的算法进行分析。最后以图表和数据的形式返回给用户，给用户最直观的显示。让用户可以清楚地看到自己的活动是否规律，是否有需要改进的地方。

当然，这次的研究还有很多不足的地方，比如存在着户自己来记录行为，算法进行的活动识别研究并不能保证极高的准确率等问题。接下来我们将逐步完善这些功能，例如可以自动地获取用户现在正在进行的行为、提高算法与模型的准确性与联系，让算法可以精确地判断用户的活动行为，甚至可以通过分析用户所处环境，与活动行为一起进行研究，提出更科学、更贴近现实生活的模型与结果。

## 致 谢

我们为向我们的实验提供数据的北京建筑大学的志愿者们表示感谢。

## 基金项目

本文受国家重点研发计划项目(2017YFB1302400)，江苏省科技计划产业前瞻与共性关键技术竞争项目(BE2018084)，2019年北京高等学校高水平人才交叉培养“实培计划”项目(29041620001)，北京2018年工信部工业互联网创新发展项目，2019年工信部工业互联网创新发展工程-工业互联网标识解析二级节点平台项目资助。

## 参考文献

- [1] 张洋, 姚登峰. 人类的行为识别分类方法综述[C]. 中国计算机用户协会网络应用分会2019年第二十三届网络新技术与应用年会论文集. 2019.
- [2] Kao, H.-L., Ho, B.J., Lin, A.C. and Chu, H.H. (2012) Phone-Based Gait Analysis to Detect Alcohol Usage. *Proceedings of the 2012 ACM Conference on Ubiquitous Computing*, Pittsburgh, September 2012, 661-662. <https://doi.org/10.1145/2370216.2370354>
- [3] Ordóñez, F.J. and Roggen, D. (2016) Deep Convolutional and LSTM Recurrent Neural Networks for Multimodal Wearable Activity Recognition. *Sensors*, **16**, 115. <https://doi.org/10.3390/s16010115>
- [4] Zheng, J.C. and Li, N.M. (2013) An Unsupervised Learning Approach to Social Circles Detection in Ego Bluetooth Proximity Network. *Proceedings of the 2013 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, Zurich, September 2013, 721-724. <https://doi.org/10.1145/2493432.2493512>
- [5] Xuan, B., Fan, S.C., et al. (2013) Your Reactions Suggest You Liked the Movie: Automatic Content Rating via Reaction Sensing. *Proceedings of the 2013 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, Zurich, September 2013, 197-206. <https://doi.org/10.1145/2493432.2493440>
- [6] Hammerla, N.Y., et al. (2015) PD Disease State Assessment in Naturalistic Environments Using Deep Learning. *Proceedings of the 29th AAAI Conference on Artificial Intelligence*, Austin, January 2015, 1742-1748.
- [7] Pourbabaee, B., Roshtkhari, M.J. and Khorasani, K. (2017) Deep Convolution Neural Networks And Learning Ecg Features For Screening Paroxysmal Atrial Fibrillation Patients. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, **48**, 2095-2104.
- [8] Parlak, S., Marsic, I. and Burd, R. (2012) Activity Recognition for Emergency Care Using RFID. *BODYNETS 2011—6th International ICST Conference on Body Area Networks*, Brussels, November 2011, 40-46. <https://doi.org/10.4108/icst.bodynets.2011.247213>
- [9] Kwon, Y., Kang, K. and Bae, C. (2016) Evaluation of a Smartphone Human Activity Recognition Application with Able-Bodied and Stroke Participants. *Journal of Neuro Engineering and Rehabilitation*.
- [10] Capela, N.A., Lemaire, E.D., Baddour, N., Rudolf, M., Goljar, N. and Burger, H. (2016) Evaluation of a Smartphone Human Activity Recognition Application with Able-Bodied and Stroke Participants. *Journal of NeuroEngineering and Rehabilitation*, **13**, Article No. 5. <https://doi.org/10.1186/s12984-016-0114-0>
- [11] Ghose, S., Mitra, J., et al. (2016) Human Activity Recognition from Smart-Phone Sensor Data Using a Multi-Class Ensemble Learning in Home Monitoring. *IEEE International Conference on Healthcare Informatics*, **214**, 62-67.