

基于改进储备池计算模型的人体行为识别

陈宇骞^{1,2}, 任旭超^{2,3}, 朱雅琳^{1,2}, 颜 延²

¹五邑大学智能制造学部, 广东 江门

²中国科学院深圳先进技术研究院, 广东 深圳

³西安石油大学计算机学院, 陕西 西安

收稿日期: 2023年2月20日; 录用日期: 2023年3月21日; 发布日期: 2023年3月31日

摘要

人体行为识别(human activity recognition, HAR)是元宇宙场景人机交互应用中的关键任务。在基于传感器的HAR任务中, 提取有用特征是提高模型性能的关键。为此, 本文提出了一种改进的储备池计算网络框架(enhanced reservoir computing network framework, ERCNF)。本文首先使用圆形储备池模块提取信号的特征, 然后使用降维模块对提取的特征进行降维, 最后使用岭回归器进行线性读出。我们在UCI-HAR和mHealth两个公开数据集上评估ERCNF模型。在UCI-HAR和mHealth数据集上ERCNF模型的准确率分别为98.1%和95.6%。该模型具有训练速度快, 准确率高等特点, 能有效地从数据中提取深度特征, 在可穿戴应用中具有良好的应用前景。

关键词

储备池计算, 回声状态网络, 特征融合, 人体行为识别

Human Activity Recognition Based on Enhanced Reservoir Computing

Yuqian Chen^{1,2}, Xuchao Ren^{2,3}, Yalin Zhu^{1,2}, Yan Yan²

¹Faculty of Intelligent Manufacturing, Wuyi University, Jiangmen Guangdong

²Shenzhen Institutes of Advanced Technology, Chinese Academy of Sciences, Shenzhen Guangdong

³College of Computer Science, Xi'an Shiyou University, Xi'an Shaanxi

Received: Feb. 20th, 2023; accepted: Mar. 21st, 2023; published: Mar. 31st, 2023

Abstract

Human activity recognition (HAR) is a critical task in human-machine interaction applications for

文章引用: 陈宇骞, 任旭超, 朱雅琳, 颜延. 基于改进储备池计算模型的人体行为识别[J]. 计算机科学与应用, 2023, 13(3): 528-536. DOI: [10.12677/csa.2023.133052](https://doi.org/10.12677/csa.2023.133052)

meta-universe scenarios. Extracting useful features are the keys to improving the model performance in a sensor-based HAR tasks. This paper proposes an enhanced reservoir computing network framework (ERCNF) to address the problems. In this work, the ERCNF model is feature extracted by the circular reservoir topology module, then the extracted features are dimensionally reduced by a dimensionality reduction module, and finally linear readout is performed by a ridge regressor. We evaluate the ERCNF model with two benchmark HAR on the datasets of UCI-HAR and mHealth. The best classification accuracies achieved by the ERCNF model are 98.1% and 95.6% with UCI-HAR and mHealth datasets, respectively. The model has fast training speed and high accuracy, and can effectively extract depth features from the data, which has good application prospects in wearable applications.

Keywords

Reservoir Computing (RC), Echo State Network, Feature Fusion, Human Activity Recognition

Copyright © 2023 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

人体行为识别是元宇宙应用和数字运动训练研究的热点之一，不同的人体动作可以被一些信息载体记录下来，比如摄像头、传感器、雷达、WiFi 信号等。随着传感器技术的不断发展，人体行为识别应用场景可以扩展到医疗康复、体育比赛、元宇宙等领域。近年来，可穿戴传感器的快速发展和接受也使 HAR 成为研究热点。与监测心率和血氧等人体生理信号传感器相结合，成为老年人跌倒检测、远程健康诊断和日常健身计划开发应用的重要组成部分。

人类的身体活动拥有固有的层次结构和细粒度的动作[1]，使用传感器收集的活动数据(如智能手机中的传感器)建模相当复杂。可穿戴位置的变化、传感器数量的变化以及不同个体带来的活动复杂性，都会造成各种各样的限制。近年来，许多研究都致力于开发基于深度学习的自动特征提取技术[2]。同时，在传感器、特征和分类器级别[3][4]中，也引入了传统基于特征的模型以及不同层次的融合框架。然而，深度学习和特征融合模型可能会因为训练速度慢、梯度爆炸或倾向于陷入局部最优[5]而给可穿戴应用带来负担。

在这项工作中，我们研究了基于传感器的 HAR 任务中的储备池计算(Reservoir Computing, RC)模型。RC 模型作为一种新型的递归神经网络，克服了上述不足。RC 具有训练速度快、短时记忆能力强、抗陷入局部最优[6]等优点。RC 通常也被称为回声状态网络(Echo State Network, ESN)，自 2002 年 Jaeger 推出[7]以来，它一直备受关注。与循环神经网络不同，RC 模型有一个不可训练的、稀疏连接的循环部分(动态库)作为隐藏层，只有输出权重需要训练。RC 的内部权重和输入权重是随机生成的，在训练和测试过程中保持不变。读出训练是一个简单的监督学习线性回归问题，具有简单性和较高的学习效率，适用于传感器信号模式识别分析问题。

本文提出了一种由圆形储备池拓扑模块、降维模块和岭回归器组成的增强型储备池计算网络框架(ERCNF)。在基于传感器的 HAR 任务中的验证表明，ERCNF 模型具有良好的识别性能和快速的训练速度，有望成为可穿戴应用的有效解决方案。

2. 研究现状

基于视觉的 HAR 方法[8] [9] [10]受到摄像机在固定区域捕获信息的限制，限制了长期随访能力。同时，由于图像信息的采集方式，基于视觉的方法缺乏隐私保护能力。相反，可穿戴设备可以持续和私密地跟踪和收集人体运动行为数据。许多机器学习算法已被广泛用于解决与 HAR 相关的问题，例如传统的基于特征学习的模型，其分类器为决策树[11]、随机森林[12]、普通贝叶斯[13]和支持向量机[14]。文献[15] [16]提出了利用支持向量机和具有时域和频域特征的随机森林的活动识别方法。在[15]中提出了一种基于描述符的内置传感器智能手机活动分类方法，该方法采用梯度直方图和傅里叶变异进行活动分类。此外，深度学习方法也得到了广泛应用。在[17]的工作中，作者提出了一种具有卷积神经网络和长短期记忆网络的整体活动识别架构，即 CNN-LSTM，在 UCI-HAR 公共数据集上达到 92% 的准确率。Abudalfa *et al.* [18] 提出了一种基于储备池计算与 SVM 相结合的算法，在自采集数据集中识别准确率为 91.7%。在[19]中提出了一种融合 CNN、递归卷积网络和 SVM 向量机的协同决策融合机制，基于 Tsallis 熵计算并融合各分类器的相对加权分数，以提高 HAR 性能。在[20] [21] [22]中也实现了各种深度学习框架和网络结构。

综上所述，传统的基于特征学习的人体行为分类方法存在特征提取算法复杂、容易过拟合的问题。虽然有研究人员使用特征选择算法来获取重要特征并降低维数，但这些分类模型受到核函数选择的限制，计算成本高。同时，基于神经网络的深度模型可以提取更多的抽象特征和判别特征，但由于模型训练所需计算资源大和数据量不足而变得复杂。因此，在本研究中，我们提出了一种基于 RC 的模型，以克服既具有良好的代表性特征提取能力又具有低部署成本的缺点。

3. 基于改进储备池计算的人体行为识别方法

3.1. 经典 RC 模型原理

经典 RC 的拓扑结构如图 1 所示[23]。图的左侧是 K 个输入节点；中间为 RC 网络，由 N 个内部节点和稀疏节点连接权组成；右边为 L 个输出节点。图中的实线表示网络的必要连接，虚线表示在不同情况下也可能存在的连接，但它们不是构成 RC 的必要连接。在 RC 模型中，只有输出连接权值在训练阶段被改变。

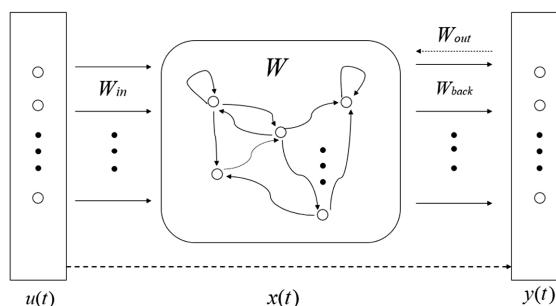


Figure 1. Framework of a reservoir computing network
图 1. 储备池计算模型的网络结构

储备池状态依照下式进行更新：

$$x(t+1) = f(W_{\text{in}}u(t+1) + Wx(t) + W_{\text{back}}y(t))$$

上式中， $x(t)$ 为第 t 步储备池状态向量， $u(t)$ 和 $y(t)$ 分别为第 t 步的输入和输出向量， $f(\cdot)$ 为储备池节点的激励函数， W_{in} 、 W_{back} 和 W 分别为储备池的输入连接、输出反馈连接和内部连接的权值矩阵。网络输出由下式计算：

$$y(t+1) = f(W_{\text{out}}(u(t+1), x(t+1), y(t)))$$

上式中, W_{out} 为输出权值矩阵。RC 的基本思想是从储备池中生成一个随输入而不断变化的复杂动态空间。当这个状态空间足够复杂时, 这些内部状态可以用来线性组合所需的相应输出。RC 的训练过程比调整内部连接矩阵权值要简单得多, 在网络初始化后的训练过程中唯一发生变化的是输出连接权值。对于输出权重的调整, 每个输出节点根据最小均方误差原则独立调整。

3.2. RC 模型改进与分析

以往对递归神经网络的研究主要集中在改进和优化误差梯度下降算法, 使其适用于递归神经网络权值的调整。但该算法收敛速度慢、计算量大等问题尚未得到很好的解决。为了捕获输入数据集的大量特征, RC 的大小变得巨大, RC 的拓扑结构变得复杂, 并且随机生成大量的连接矩阵权重。然而, 复杂的拓扑结构也增加了算法的复杂度, 降低了算法的实用性。因此, 我们选择引入一个圆形 RC 模型[24], 它在捕获输入特征和使内存容量(Memory Capacity, MC)更有效; 同时, 将降维模块和岭回归相结合, 提出了一种改进的 HAR 方法。

由于储备池的高维度, [25]中预测模型的参数数量会变得过多, 使得所提出的表示难以处理。在 RC 的情况下, 应用 PCA 来降低最后一个储备池状态的维数已被证明可以提高推理任务的性能[26]。与非线性降维方法(如核 PCA 或自编码器[27])相比, PCA 与 RC 模型结合时提供了具有竞争力的泛化能力, 并且由于其线性公式[28], 可以快速计算。高阶张量的降维可以通过将张量分解为核心张量(低维表示)来实现。降维模块使用无监督准则将 RC 激活序列投射到低维向量上。采用的降维算法为 PCA, 将特征投影到协方差矩阵的特征向量上。每个多元时间序列都与分类任务中的不同状态序列相关联。

在降维和表示法之后, 需要将表示法分类并实现为线性读出。在标准 RC 模型中, 读数是线性的, 并通过求解凸优化问题快速训练。然而, 线性读数可能不能充分代表从储备池状态导出的模型嵌入。因此, 本文选择岭回归非线性模型代替线性解码函数。

圆形 RC 模型处理输入的多元时间序列, 生成随时间变化的状态序列。然后利用主成分分析降维方法对储备池特征进行降维, 生成新的储备池特征序列。在此之后, 一个新的序列训练一个独立的储备池状态模型来生成新的特征。最后用岭回归法读出分类结果。

对输入的多元时间序列 X 进行圆形 RC 模型处理, 生成随时间变化的状态序列。然后利用主成分降维方法减少储备池特征的数量, 生成新的储备池特征序列。让新序列训练一个独立的储备池状态模型来预测 $h(n)$, 其中 $\theta_h[n]$ 表示 $X(n)$ 。最后用岭回归法读出分类结果。

模型结构如图 2 所示。利用圆形 RC 模块对模型进行特征提取, 然后用 PCA 模块对提取的特征进行降维, 最后用岭回归器进行线性读出。

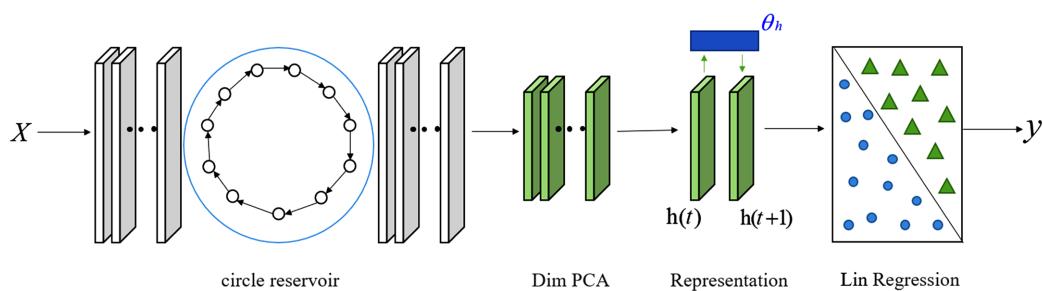


Figure 2. Framework overview

图 2. 整体结构

4. 实验与讨论

在这项工作中，我们使用两个基于传感器的 HAR 数据集来验证改进的 RC 模型的分类能力；每个数据集都有不同数量的传感器位置和活动标签。UCI-HAR 和 mHealth 这两个公共开放数据集被广泛用于基于传感器的 HAR 模型评估。接下来将描述所使用的数据集，以及对每个数据集进行分析的实验结果。

4.1. 数据集介绍

4.1.1. UCI-HAR 数据集

UCI-HAR 数据集基于用于活动识别的智能手机传感器数据。这些数据来自 30 名年龄在 19 岁至 48 岁之间的志愿者，他们将智能手机绑在腰上，进行六项标准活动中的一项，并通过开发的手机软件记录运动数据。还记录了每个志愿者进行活动的视频，然后根据该视频和传感器数据手动标记他们所属的运动类别(类似于剪辑视频中的视听同步)。使用其嵌入式加速度计和陀螺仪以 50 Hz 的恒定速率捕获 3 轴线性加速度和 3 轴角速度。该实验已被录像，以手动注释。进行的六项活动是：走(walking)、走上楼(walking upstairs)、走下楼(walking downstairs)、坐(sitting)、站(standing)和躺(laying)。

4.1.2. mHealth 数据集

mHealth 数据集包括 10 名不同背景的志愿者在进行多项体育活动时的身体运动和生命体征记录。放置在受试者胸部、右手腕和左腕关节上的传感器用于测量不同身体部位的运动，即加速度、转弯速率和磁场方向，所有传感模式都以 50 Hz 的采样率记录。具体的活动有站着不动(standing still)、坐着(sitting)、躺着(lying)、走(walking)、爬楼梯(climbing stairs)、腰前屈(waist bends forward)、手臂正面抬高(the frontal elevation of arms)、膝盖弯曲(knees bending)、骑自行车(cycling)和慢跑(jogging)。关于实验数据收集的详细信息，请参见[29] [30]。

4.2. 参数分析

由于 RC 光谱半径和 RC 节点数 N 是基本参数，本节提供了光谱半径的参数分析。如图 3 所示，当谱半径一定时，平均分类准确率随着 N 的增加而增加，UCI-HAR 数据集 N 为 3500 时，验证集的平均分类准确率最高。当 mHealth 数据集 N 为 400 时，验证集的平均分类准确率最高。本文后续所有实验均采用该参数分析的结果进行。

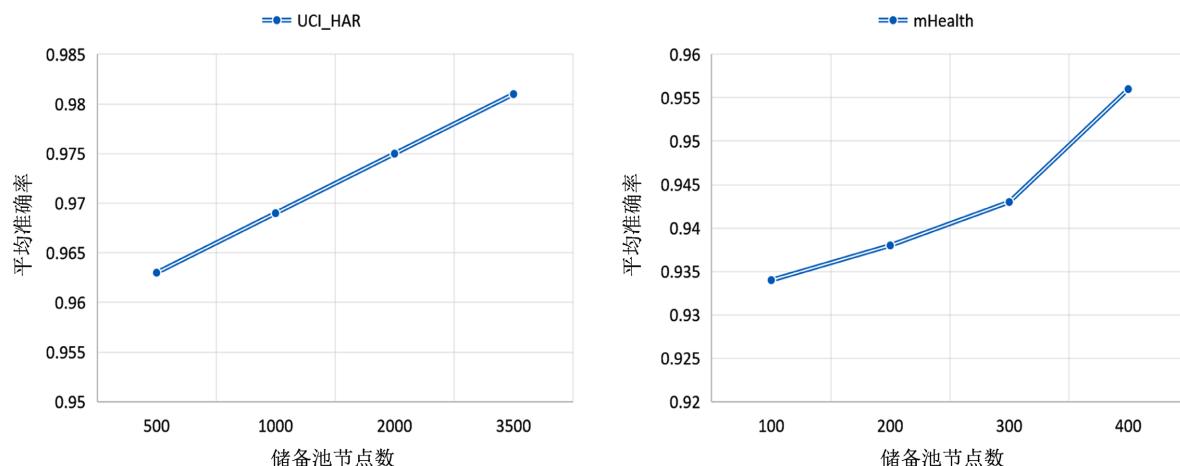


Figure 3. Reservoir size comparisons of classification performance for UCI-HAR and mHealth

图 3. UCI-HAR 和 mHealth 分类性能对应储备池节点数大小的比较

如表1所示，使用ERCNF可以有效地减少模型的训练时间。当使用UCI-HAR数据集在同一设备上训练神经网络时，设置RC与ERCNF的节点数N和光谱半径等参数一致，使用CNN网络的训练时间为62.40秒，使用RC网络的训练时间为8.16秒，而使用ERCNF将训练时间减少到5.64秒。结果表明，使用ERCNF可以降低算法的复杂度，从而提高算法的实用性。

Table 1. Comparison of training time between CNN, RC and EERCNF on the UCI-HAR and mHealth datasets
表1. CNN、RC 和 EERCNF 在 UCI-HAR 和 mHealth 数据集上训练时间的比较

dataset	Time		
	CNN	RC	ERCNF
UCI-HAR	62.40	8.16	5.64
mHealth	8.41	0.95	0.52

4.3. 结果讨论

在本节中，我们尝试使用精度和F1-score矩阵等经典指标来评估模型的分类性能。准确率是分类器正确分类的样本数量与样本总数的比值。F1分数是一个结合了准确率和召回率的指标。

本文采用了准确率(Accuracy)和F1值(F1-score)两个评价指标。它们的定义分别如下式所示：

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}$$

$$\text{F1} = \frac{2\text{TP}}{2\text{TP} + \text{FP} + \text{FN}}$$

其中TP为真情况，表示从正类预测到正类的样本数；TN为真负情况，表示从负类预测到负类的样本数；FP为假阳性情况，表示从阳性类预测到阴性类的样本数量；FN为假阴性情况，表示从阴性类预测到阳性类的样本数。

Table 2. System resulting data of standard experiment

表2. 标准试验系统结果数据

dataset	Accuracy					
	SVM	random forest	Bayesian	CNN	ESN	ERCNF
UCI-HAR	90.5%	93.6%		93.2%	90.3%	98.1%
mHealth	90.8%	85.27%	90.80%	82.98%	91.1%	95.6%

如表2所示，在UCI-HAR和mHealth数据集上，ERCNF的分类准确率分别为98.1%和95.6%，比经典RC模型分别提高了7.8%和4.5%。SVM模型在mHealth数据集上优于CNN，这是因为CNN容易陷入局部最优，而SVM可以有效地解决这一问题。然而，支持向量机的非线性数据处理能力不足，而RC模型可以较好地解决上述两个问题。最终，可以得出ERCNF也具有比传统机器学习和卷积神经网络更高的分类精度。

UCI-HAR和mHealth数据集上的实验结果见表3和表4。UCI-HAR和mHealth的总体准确率分别为98.1%和95.6%。此外，UCI-HAR所涉及的六项活动的平均准确率、回忆率和F1得分分别为98.08%、98.07%和98.06%；mHealth中12项相关活动的平均准确率、召回率和F1得分分别为95.54%、95.56%和95.50%。

Table 3. Classification results with the proposed ERCNF approach for the UCI-HAR datasets
表 3. UCI-HAR 数据集的 ERCNF 方法分类结果

Dataset	UCI-HAR		
Labels/Metrics	Pre	Recall	F1-Score
walking	1.00	0.99	0.99
walking upstairs	1.00	0.99	0.99
walking downstairs	0.98	1.00	0.99
sitting	0.97	0.93	0.95
standing	0.95	0.98	0.96
laying	0.99	1.00	1.00
Average	0.98	0.98	0.98
Overall Accuracy	0.98		

Table 4. Classification results with the proposed ERCNF approach for the mHealth datasets
表 4. 采用 ERCNF 方法对 mHealth 数据集进行分类

Dataset	mHealth		
Labels/Metrics	Pre	Recall	F1-Score
standing still	97.92	97.92	97.92
sitting	97.94	98.96	98.45
lying	98.92	95.83	97.35
walking	95.70	92.71	94.18
climbing stairs	93.14	98.96	95.96
waist bends forward	95.24	96.39	95.81
frontal elevation of arms	96.59	97.70	97.14
knees bending	96.74	96.74	96.74
cycling	97.94	98.96	98.45
jogging	94.57	90.62	92.55
running	89.11	93.75	91.37
jumping front back	89.47	79.09	83.95
Average	95.54	95.53	95.50
Overall Accuracy	95.53		

5. 结论

本文提出了一种新的基于改进储备池计算的人体行为识别的特征提取方法。利用两个公开的传感器数据集，我们使用 ERCNF 模型对人体行为进行分类，获得了良好的识别精度。同时，所提出的方法在训练上比经典深度学习模型更快。这项工作为元宇宙使用和运动训练应用中的 HAR 任务提供了一个很好的解决方案。本研究的不足之处在于 ERCNF 模型的有效性仅在两个公共数据集上进行了评估，后续还需要在更多数据集上进行测试，以验证该方法的泛化能力。

基金项目

广东省 2019 年省拨高建“冲补强”专项项目(编号: 5041700175); 教育部第二批新工科研究与实践项目(编号: E-RGZN20201036)。

参考文献

- [1] Ronao, C.A. and Cho, S.B. (2016) Human Activity Recognition with Smartphone Sensors Using Deep Learning Neural Networks. *Expert Systems with Applications*, **59**, 235-244. <https://doi.org/10.1016/j.eswa.2016.04.032>
- [2] Palumbo, F., Gallicchio, C., Pucci, R. and Micheli, A. (2016) Human Activity Recognition Using Multisensor Data Fusion Based on Reservoir Computing. *Journal of Ambient Intelligence and Smart Environments*, **8**, 87-107. <https://doi.org/10.3233/AIS-160372>
- [3] Ehatisham-Ul-Haq, M., Javed, A., Azam, M.A., Malik, H.M., Irtaza, A., Lee, I.H. and Mahmood, M.T. (2019) Robust Human Activity Recognition Using Multimodal Feature-Level Fusion. *IEEE Access*, **7**, 60736-60751. <https://doi.org/10.1109/ACCESS.2019.2913393>
- [4] Nweke, H.F., Teh, Y.W., Mujtaba, G. and Al-Garadi, M.A. (2019) Data Fusion and Multiple Classifier Systems for Human Activity Detection and Health Monitoring: Review and Open Research Directions. *Information Fusion*, **46**, 147-170. <https://doi.org/10.1016/j.inffus.2018.06.002>
- [5] Bengio, Y., Simard, P. and Frasconi, P. (1994) Learning Long-Term Dependencies with Gradient Descent Is Difficult. *IEEE Transactions on Neural Networks*, **5**, 157-166. <https://doi.org/10.1109/72.279181>
- [6] Jaeger, H., Maass, W. and Principe, J. (2007) Special Issue on Echo State Networks and Liquid State Machines. *Neural Networks*, **20**, 287-289. <https://doi.org/10.1016/j.neunet.2007.04.001>
- [7] Nyan, M.N., Tay, F.E.H., Seah, K.H.W. and Sitoh, Y.Y. (2006) Classification of Gait Patterns in the Time-Frequency Domain. *Journal of Biomechanics*, **39**, 2647-2656. <https://doi.org/10.1016/j.jbiomech.2005.08.014>
- [8] Lin, T., Liu, X., Li, X., Ding, E., & Wen, S. (2019) BMN: Boundary-Matching Network for Temporal Action Proposal Generation. ArXiv: 1907.09702.
- [9] Wang, L.M., Xiong, Y.J., Wang, Z., et al. (2016) Temporal Segment Networks: Towards Good Practices for Deep Action Recognition. In: Leibe, B., Matas, J., Sebe, N. and Welling, M., Eds., *Computer Vision—ECCV 2016. Lecture Notes in Computer Science*, Vol. 9912, Springer, Cham, 22-36. https://doi.org/10.1007/978-3-319-46484-8_2
- [10] Lan, Z.Z., Zhu, Y., Hauptmann, A.G. and Newsam, S. (2017) Deep Local Video Feature for Action Recognition. 2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Honolulu, 21-26 July 2017, 1219-1225. <https://doi.org/10.1109/CVPRW.2017.161>
- [11] Fan, L., Wang, Z. and Wang, H. (2013) Human Activity Recognition Model Based on Decision Tree. 2013 International Conference on Advanced Cloud and Big Data, Nanjing, 13-15 December 2013, 64-68. <https://doi.org/10.1109/CBD.2013.19>
- [12] Hu, C., Chen, Y., Hu, L. and Peng, X. (2018) A Novel Random Forests Based Class Incremental Learning Method for Activity Recognition. *Pattern Recognition*, **78**, 277-290. <https://doi.org/10.1016/j.patcog.2018.01.025>
- [13] Xiao, Q. and Song, R. (2018) Action Recognition Based on Hierarchical Dynamic Bayesian Network. *Multimedia Tools and Applications*, **77**, 6955-6968. <https://doi.org/10.1007/s11042-017-4614-0>
- [14] Chathuramali, K.G.M. and Rodrigo, R. (2012) Faster Human Activity Recognition with SVM. *International Conference on Advances in ICT for Emerging Regions (ICTer2012)*, Colombo, 12-15 December 2012, 197-203.
- [15] Jain, A. and Kanhangad, V. (2017) Human Activity Classification in Smartphones Using Accelerometer and Gyroscope Sensors. *IEEE Sensors Journal*, **18**, 1169-1177. <https://doi.org/10.1109/JSEN.2017.2782492>
- [16] Liu, R., Wang, Z., Shi, X., et al. (2019) Table Tennis Stroke Recognition Based on Body Sensor Network. In: Montella, R., Ciaramella, A., Fortino, G., Guerrieri, A. and Liotta, A., Eds., *Internet and Distributed Computing Systems. IDCS 2019. Lecture Notes in Computer Science*, Vol. 11874, Springer, Cham, 1-10. https://doi.org/10.1007/978-3-030-34914-1_1
- [17] Mutegeki, R. and Han, D.S. (2020) A CNN-LSTM Approach to Human Activity Recognition. 2020 International Conference on Artificial Intelligence in Information and Communication (ICAIC), Fukuoka, 19-21 February 2020, 362-366. <https://doi.org/10.1109/ICAIC48513.2020.9065078>
- [18] Abudalfa, S., Bouchard, K. (2021). Hybrid Deep-Readout Echo State Network and Support Vector Machine with Feature Selection for Human Activity Recognition. In: Deze, Z., Huang, H., Hou, R., Rho, S. and Chilamkurti, N., Eds., *Big Data Technologies and Applications. BDTA WiCON 2020 2020. Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering*, Vol. 371, Springer, Cham, 150-167.

- https://doi.org/10.1007/978-3-030-72802-1_11
- [19] Arigbabu, O.A. (2020) Entropy Decision Fusion for Smartphone Sensor Based Human Activity Recognition. ArXiv: 2006.00367.
 - [20] Ogbuabor, G. and La, R. (2018) Human Activity Recognition for Healthcare using Smartphones. *Proceedings of the 2018 10th International Conference on Machine Learning and Computing*, Macau, 26-28 February 2018, 41-46. <https://doi.org/10.1145/3195106.3195157>
 - [21] Palumbo, F., Barsocchi, P., Gallicchio, C., Chessa, S. and Micheli, A. (2013) Multisensor Data Fusion for Activity Recognition Based on Reservoir Computing. In: Botía, J.A., Álvarez-García, J.A., Fujinami, K., Barsocchi, P. and Riedel, T., Eds., *Evaluating AAL Systems through Competitive Benchmarking. EvaAAL 2013. Communications in Computer and Information Science*, Vol. 386, Springer, Berlin, 24-35. https://doi.org/10.1007/978-3-642-41043-7_3
 - [22] Wan, S., Qi, L., Xu, X., Tong, C. and Gu, Z. (2020) Deep Learning Models for Real-time Human Activity Recognition with Smartphones. *Mobile Networks and Applications*, **25**, 743-755. <https://doi.org/10.1007/s11036-019-01445-x>
 - [23] Jaeger, H. (2001) The ‘Echo State’ Approach to Analyzing and Training Recurrent Neural Networks: GMD Report 148. German National Research Center for Information Technology, St. Augustin.
 - [24] Jaeger, H., Lukosevicius, M., Popovici, D. and Siewert, U. (2007) Optimization and Applications of Echo State Networks with Leaky-Integrator Neurons. *Neural Networks*, **20**, 335-352. <https://doi.org/10.1016/j.neunet.2007.04.016>
 - [25] Baydogan, M.G. and Runger, G. (2015) Learning a Symbolic Representation for Multivariate Time Series Classification. *Data Mining and Knowledge Discovery*, **29**, 400-422. <https://doi.org/10.1007/s10618-014-0349-y>
 - [26] Bianchi, F.M., Scardapane, S., Løkse, S. and Jenssen, R. (2017) Bidirectional Deep-Readout Echo State Networks. ArXiv: 1711.06509.
 - [27] Bianchi, F.M., Livi, L., Mikalsen, K.Ø., Kampffmeyer, M. and Jenssen, R. (2019) Learning Representations of Multivariate Time Series with Missing Data. *Pattern Recognition*, **96**, Article ID: 106973. <https://doi.org/10.1016/j.patcog.2019.106973>
 - [28] Løkse, S., Bianchi, F.M. and Jenssen, R. (2017) Training Echo State Networks with Regularization Through Dimensionality Reduction. *Cognitive Computation*, **9**, 364-378. <https://doi.org/10.1007/s12559-017-9450-z>
 - [29] Banos, O., Garcia, R., Holgado-Terriza, J.A., Damas, M., Pomares, H., Rojas, I., Saez, A. and Villalonga, C. (2014) mHealthDroid: A Novel Framework for Agile Development of Mobile Health Applications. In: Pecchia, L., Chen, L.L., Nugent, C. and Bravo, J., Eds., *Ambient Assisted Living and Daily Activities. IWAAL 2014. Lecture Notes in Computer Science*, Vol. 8868, Springer, Cham, 91-98. https://doi.org/10.1007/978-3-319-13105-4_14
 - [30] Banos, O., Villalonga, C., Garcia, R., Saez, A., Damas, M., Holgado-Terriza, J.A., Lee, S., Pomares, H. and Rojas, I. (2015) Design, Implementation and Validation of a Novel Open Framework for Agile Development of Mobile Health Applications. *BioMedical Engineering OnLine*, **14**, Article No. S6. <https://doi.org/10.1186/1475-925X-14-S2-S6>