

DOI: 10.7652/xjtuxb201904018

非接触式身份识别的深度学习算法

余星达¹, 陈文杰¹, 王鼎¹, 曹仰杰¹, 陈荟慧²

(1. 郑州大学软件学院, 450000, 郑州; 2. 佛山科学技术学院电子信息工程学院, 528000, 广东佛山)

摘要: 针对传统基于 Wi-Fi 的身份识别方法手工编码特征效率低、准确率不高的问题,提出一种基于深度学习的非接触式身份识别(WiID)算法。该算法通过分析子载波中信道状态信息数据的空间相关性,建立了用于深度学习的输入矩阵;采用二维卷积运算从相邻子载波中提取局部空间特征;构建门限循环单元层,从时间维度对空间特征进行时序建模,完成空间与时间两个维度的步态特征提取,实现端到端的非接触式身份识别,有效减少了数据预处理工作量。实验结果表明,与卷积神经网络和循环神经网络算法相比,该算法识别准确率得到了有效提高;在 6 种不同的实验场景下,该算法的身份识别准确率介于 92.9%~95.6%之间,具有良好的身份识别效果及算法鲁棒性。

关键词: 非接触式身份识别;深度学习;信道状态信息

中图分类号: TP391 **文献标志码:** A **文章编号:** 0253-987X(2019)04-0122-06

A Deep Learning Algorithm for Contactless Human Identification

YU Xingda¹, CHEN Wenjie¹, WANG Ding¹, CAO Yangjie¹, CHEN Huihui²

(1. School of Software Engineering, Zhengzhou University, Zhengzhou 450000, China;

2. School of Electronic and Information Engineering, Foshan University, Foshan, Guangdong 528000, China)

Abstract: A contactless human identification algorithm WiID based on deep learning is proposed to solve the problem that traditional Wi-Fi-based human identification methods have low efficiency of manual feature extraction and low accuracy. An input matrix for deep learning is established by analyzing the spatial correlation of channel state information data in subcarriers. The two-dimensional convolution operation is used to extract local spatial features from adjacent subcarriers, and spatial features are modeled from the temporal dimension through the gated recurrent unit layer. Gait feature extractions in both spatial and temporal dimensions are performed, and the end-to-end contactless human identification is realized to effectively reduce the workload of data preprocessing. Experimental results and comparisons with the convolutional neural network and recurrent neural network show that the identification accuracy of the proposed algorithm is effectively improved. The identification accuracy of the proposed algorithm under six different scenarios ranges from 92.9% to 95.6%, and the algorithm has good identification effect and robustness.

Keywords: contactless human identification; deep learning; channel state information

身份识别是普适计算和人机交互领域的重要研究内容,在安防系统中发挥着关键作用。脸像、指纹

收稿日期: 2018-10-31。 作者简介: 余星达(1992—),男,硕士生;曹仰杰(通信作者),男,副教授,硕士生导师。 基金项目: 国家自然科学基金资助项目(61602230)。

网络出版时间: 2019-01-24

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1069.T.20190122.0917.012.html>

和虹膜等近距离的身份识别在实际应用中受到了诸多限制^[1]。步态具备远距离感知、非接触、难以隐藏等特性,被公认为人类的独特生物特征^[2],受到了研究者的广泛关注。步态识别的前期研究中,研究者使用摄像机^[3]、加速度传感器^[4]或地面传感器^[5]对识别方法进行了大量尝试,这些方法易受光线等环境因素或部署条件的限制,不适合室内身份识别。随着室内环境中 Wi-Fi 信号的大规模覆盖,基于 Wi-Fi 信号的行为感知成为新兴的研究领域。Wi-Fi 感知方式是非接触式的,不受光线限制,设备部署方式灵活,被检测目标无需携带任何设备,而且由于体型和运动模式的差异,每个人的步态以独有的方式影响周围 Wi-Fi 信号,从而在信道状态信息(CSI)上产生独特的模式^[6],因此研究人员开始探索利用 Wi-Fi 信号进行身份识别。

通过采集 Wi-Fi 的 CSI 数据,Zeng 等提出了一种身份识别方法(WiWho),利用多径消除和带通滤波去除噪声,并提取步行的特征进行身份识别,在 2~6 人的团体中识别出一个人的准确率为 92%~80%^[7];Xin 等提出了一种 FreeSense 的方法,该方法使用主成分分析和离散小波变换提取视距路径波形的形状特征,并通过最近邻分类器进行身份识别,在 6 人情况下的识别率为 88.9%^[6];Zhang 等提出的 Wi-Fi-ID 通过连续小波变换提取不同频段的信号,利用 ReliefF 特征选择算法计算所选频段的时域和频域特征作为每个人的特征库,在 2~6 人团体达到了 93%~77% 的识别率^[8]。

上述研究工作在身份识别中取得了一定的效果,但由于 CSI 描述了传输信号的散射、衰落、多普勒频移等综合效应^[9],传统的手工特征提取方法需要大量的数据预处理工作,难以提取有效的特征以提高身份识别准确率。由于 CSI 能够在子载波级别刻画多径传播,当行为发生时,不同天线对和子载波的 CSI 变化是相关联的^[10],因此本文利用深度学习提取 CSI 数据的时空特征,设计了一种端到端的非接触式身份识别(WiID)算法,该算法使用 CSI 数据的幅度信息构建输入矩阵,通过卷积层提取子载波中 CSI 数据的空间特征,然后利用门限循环单元(GRU)^[11]获取其时间维度特征,取得了良好的身份识别效果。

1 WiID 算法模型

1.1 问题定义

商用 Wi-Fi 设备通常具有多个用于多输入多输

出(MIMO)通信的天线对,每个天线对的 CSI 数据包含子载波的幅度和相位信息^[12],可表示如下

$$H(f_k) = \|H(f_k)\| e^{j\angle H(f_k)}, k \in [1, K] \quad (1)$$

式中: $H(f_k)$ 是第 k 个子载波的 CSI,它是一个复数值, $\|H(f_k)\|$ 和 $\angle H(f_k)$ 分别表示其幅度和相位,WiID 算法使用幅度信息构建输入矩阵。

令 $H_k = \|H(f_k)\|$,代表第 k 个子载波的 CSI 信息。在 MIMO 系统中, N_t 和 N_r 分别代表发射和接收天线的数量,构成 $N_t \times N_r$ 个天线对,令 $N = N_t \times N_r$,因此 MIMO 系统中第 k 个子载波的 CSI 信息 H_k 表示为

$$H_k = [H_k^1, H_k^2, \dots, H_k^n, \dots, H_k^N] \quad (2)$$

式中 H_k^n 表示第 n 个天线对中第 k 个子载波的 CSI 信息。

为了检测步态特征,需要不断收集均匀时间间隔测量的 CSI 信息, J 个时刻收集的信息被表示为 CSI 序列,作为 WiID 模型的输入矩阵如下

$$\mathbf{X} = \begin{bmatrix} H_{11} & H_{12} & \dots & H_{1K} \\ H_{21} & H_{22} & \dots & H_{2K} \\ \vdots & \vdots & & \vdots \\ H_{J1} & H_{J2} & \dots & H_{JK} \end{bmatrix} \quad (3)$$

式中 H_{JK} 表示 J 时刻第 K 个子载波的 CSI 信息。

为了方便问题的定义,将式(3)表示为 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_j, \dots, \mathbf{x}_J]^T, j \in J$ 。带有身份标签的 CSI 数据集表示为 $\mathbf{D} = \{(\mathbf{X}_i, \mathbf{Y}_i)\}_{i=1}^I, \mathbf{D}$ 包含 I 个 CSI 序列及其标签。对于每个 $i=1, \dots, I, \mathbf{X}_i$ 表示第 i 个 CSI 序列, $\mathbf{Y}_i$ 是分类值,即身份标签。WiID 身份识别问题是建立一个模型,根据输入 $\mathbf{X}$ 预测身份标签 $\mathbf{Y}$ 。

1.2 WiID 算法的结构

WiID 算法的模型结构如图 1 所示,由 4 部分组成,分别是卷积层(C_1, C_2, C_3)、GRU 层(G_4, G_5)、池化层(S_6)和分类层(L_7)。通过卷积层和 GRU 层依次对 CSI 数据执行特征提取,然后将提取的特征输入至池化层进行降维以增强分类的准确性,再对降维后的特征进行分类。接下来将描述每层的工作原理和设计。

(1)卷积层。WiID 算法使用 3 层卷积层 C_1, C_2, C_3 ,通过二维卷积运算提取空间特征,如下式

$$\mathbf{S}(p, q) = (\mathbf{X} * \mathbf{C})(p, q) = \sum_j \sum_k \mathbf{X}(j, k) \mathbf{C}(p-j, q-k) \quad (4)$$

式中: $*$ 代表卷积运算; $\mathbf{C}$ 是卷积核^[13]。

WiID 算法采用滑动窗口,每次选取一段时间内采集的 CSI 序列作为模型的输入,滑动窗口的大

小为 500 ms,步长为 200,同时 WiID 算法使用了 3 个天线对,每个天线对子载波数量为 30,因此卷积层 C_1 的输入是一个大小为 500×90 、行和列分别代表时间维度、子载波维度的矩阵。在卷积层 C_1 中,为了从不同天线对的每个子载波中提取特征,使用 30 个 100×3 的卷积核对输入进行卷积操作,并且设置时间维度(垂直方向)的步长为 1,子载波维度(水平方向)的步长为 3,从而得到 30 个特征图,每个特征图的大小为 401×30 ;在卷积层 C_2 中,使用 30 个 100×5 的卷积核对 C_1 层的特征图进行卷积操作,并在水平和垂直方向上步长都设置为 1,得到 30 个大小为 302×26 的特征图;在卷积层 C_3 中,使用与 C_2 层相同的卷积操作,得到 30 个大小为 203×22 的特征图。各卷积层使用线性整流函数(ReLU)作为激活函数^[14],并且为了加速网络的训练,每个卷积层的输入都加入批标准化(BN)处理^[15]。

(2)GRU 层。GRU 层在卷积层的基础上获取时间维度信息,该层通过内置在结构单元中的“门”提取特征,解决传统循环神经网络(RNN)处理长期依赖问题时面临的梯度爆炸或者梯度消失问题^[16],其工作原理如下式

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (5)$$

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (6)$$

$$\tilde{h}_t = \tanh(W_h x_t + U_h (r_t \odot h_{t-1}) + b_h) \quad (7)$$

$$h_t = (1 - z_t) h_{t-1} + z_t \tilde{h}_t \quad (8)$$

式中:在 t 时刻,GRU 激活值 h_t 是前一时间刻激活值 h_{t-1} 和候选激活值 $\tilde{h}_t$ 的线性插值; r_t 和 z_t 分别代表重置门和更新门,重置门控制忽略信息的程度,更新门控制 h_{t-1} 传递到 h_t 的信息量; x_t 表示当前神经元的输入值; σ 表示 sigmoid 函数; $W_r, W_z, W_h, U_r, U_z, U_h$ 是系数矩阵; b_r, b_z, b_h 是偏置; $\odot$ 是对应元素数乘运算。




图1 WiID 算法的模型结构

卷积层的输出是 $203 \times 22 \times 30$ 维的张量,其中 203 对应的是时间维度信息,所以在 G_4 层每个时刻的输入是 660 维的向量。使用 G_4 和 G_5 两个 GRU 层提取时间相关的特征,每层的神经元数目为 128,并在两层之间使用 dropout 方法防止过拟合^[17]。

(3)池化层。GRU 单元获取了不同时间尺度的信息,然而只使用最后时刻的 GRU 单元信息难以刻画完整的时间特征,因此 WiID 算法通过将 G_5 层中所有 GRU 的输出作为池化层的输入,然后获得降维后的特征,有效地利用每个时刻的 GRU 单元信息。

池化在卷积神经网络中用来降低卷积层输出的特征向量的维度^[18],同时还可以起到预防过拟合的效果,其目的是用一个值来表示一个区域^[19]。WiID 算法需要利用池化结合每个时刻的 GRU 信息,所以采用均值池化层。将 G_5 层的所有单元信息输入到均值池化层得到降维后的特征

$$h_{\text{avg}} = \text{avg}([h_1, h_2, \dots, h_t, \dots, h_T]) \quad (9)$$

然后将降维后的特征 h_{avg} 线性化得到输出 z ,如下式

$$z = W h_{\text{avg}} + b \quad (10)$$

式中: W 和 b 分别代表系数矩阵和偏置。

(4)分类层。将池化层的结果输入到分类层中进行分类,分类层通过 softmax 逻辑回归计算输入序列所对应标签的预测概率分布,计算方法如下

$$P(y | x) = \frac{e^{z_y}}{\sum_{c=1}^c e^{z_y}}, y \in [1, c] \quad (11)$$

式中: c 为 y 的分类数; $P(y | x)$ 为由模型预测的输入 x 属于类别 y 的后验概率。

2 WiID 算法身份识别实验与分析

2.1 CSI 数据收集

在大厅和实验室两个典型的室内环境中收集

CSI 数据进行实验,前者是较为稀疏的多径环境,如图 2a 所示;后者则是较为复杂的多径环境,如图 2b 所示。TP_LINK AC1750 路由器作为发射器,安装了 Intel 5300 网卡的 ThinkPad x201 笔记本电脑作为接收器,两台设备相距 2.5 m。使用安装了定制驱动程序^[20]的 Ubuntu 14.04 系统收集 CSI 数据,发射器和接收器天线数分别为 $N_t=1$ 和 $N_r=3$,每个天线对包含 30 个子载波。



(a) 大厅环境 (b) 实验室环境

图 2 实验环境

为了减少环境中其他 Wi-Fi 信号的干扰,本文的实验均在 5 GHz 频段上进行,并且以 1 kHz 的采样频率收集 CSI 数据。有 6 名参与者参加了实验,参与者包括男性和女性,年龄在 18~30 岁之间。数据采集时每个人沿着预定的路径行走,预定的路径设置在发射器和接收器之间,路径宽度为 1 m,参与者来回地穿过视距路径(LOS),每次行走时间为 5 s,循环行走 100 次。

2.2 实验设置

对于收集的 CSI 数据,使用参与者姓名作为标签输入神经网络进行监督学习,WiID 算法模型的学习率设置为 0.000 1,使用 Adam 优化器最小化损失。采用 10 倍交叉验证策略,将 CSI 数据分成 10 份,9 份作为训练数据,剩余 1 份作为测试数据,交叉重复 10 次实验,取平均值评价算法识别效果。

2.3 评价指标

本文采用准确率(A)、召回率(R)和精准率(P)评估算法识别效果。

$$A = \frac{T_P + T_N}{T_P + T_N + F_N + T_N} \tag{12}$$

$$R = \frac{T_P}{T_P + F_N} \tag{13}$$

$$P = \frac{T_P}{T_P + F_P} \tag{14}$$

其中 T_P 、 F_P 、 F_N 、 T_N 分别表示属于该类且被分类器分为该类的样本数、不属于该类但被分类为该类的样本数、属于该类但被分类为不属于该类的样本数、不属于该类且被分类为不属于该类的样本数。

2.4 实验分析

2.4.1 不同人数的准确率 图 3 给出了两种室内环境下不同人数的识别准确率。当识别人数由 2 人增加到 6 人,WiID 算法在大厅和实验室环境中身份识别的准确率分别为 98.9%~95.6% 和 98.1%~93.7%。随着识别人数的增加,两种室内环境下的身份识别准确率均逐渐降低,这是由于人的体型与运动模式具有相似性,增加识别人数会降低步态特征的差异性,从而增大错误分类的概率。




图 3 两个室内环境下不同人数的识别准确率

图 4 给出了当识别人数为 6 时,在两种室内环境下身份识别实验的混淆矩阵,其中行代表标签中给定的真实身份,列代表 WiID 算法预测的身份,混淆矩阵中的 A、B、C、D、E、F 分别代表 6 名参与者。混淆矩阵中显示了参与者们的身份识别细节,对于

		预测的身份					
		A	B	C	D	E	F
真实的身份	A	230	1	3	3	1	2
	B	1	224	0	9	5	1
	C	0	4	231	1	4	0
	D	0	7	0	231	2	0
	E	6	0	4	1	227	2
	F	2	0	4	0	0	234

(a) 大厅环境

		预测的身份					
		A	B	C	D	E	F
真实的身份	A	221	0	2	0	7	10
	B	5	227	1	6	1	0
	C	1	0	230	7	2	0
	D	3	3	5	225	1	3
	E	1	0	6	2	229	2
	F	2	5	9	0	6	218

(b) 实验室环境

图 4 不同环境下 6 人识别的混淆矩阵

不同的参与者,在大厅实验环境中召回率的范围为 93.3%~97.5%,精准率的范围为 94.2%~97.9%。在实验室环境中,召回率和精准率的范围分别为 90.8%~95.8%和 90.9%~96.5%。由于在大厅这类多径传播较为稀疏的环境下,参与者行走对 Wi-Fi 信号造成的干扰相对于其他干扰来说更加显著,因此更有利于信道状态信息中步态特征的提取,从而达到了更优的身份识别效果。

2.4.2 不同采样频率的影响 为了验证 CSI 采样频率是否会影响 WiID 算法身份识别准确率,在大厅环境下的 6 人身份识别实验中,改变收集 CSI 数据集的采样时间间隔,并对采集的数据进行 10 倍交叉验证实验。当采样频率从 1 000 Hz 降低到 800 Hz 时,识别准确率从 95.6%降低以 93.3%,WiID 算法仍然保持较高的识别率,但当采样频率降低到 500 Hz 时,识别准确率降低到 89.1%。实验结果表明,小幅降低 CSI 采样频率不会对 WiID 算法身份识别的准确率造成过大影响;但在过低的采样频率下,无法采集到足够的样本数据量,不利于深度学习模型的训练,难以达到良好的识别率。

2.4.3 评估不同模型 为了更好地评估模型性能,在大厅环境下的 6 人身份识别实验中,分别使用卷积神经网络(CNN)、循环神经网络和 WiID 算法进行实验。其中卷积神经网络包含 3 个卷积层,卷积的方式与 WiID 算法卷积层相同,并且在卷积层后面添加了两个全连接层。循环神经网络包含两个 GRU 层,参数设置与 WiID 算法的 GRU 层相同。3 种算法的实验结果见表 1。

表 1 3 种算法的实验结果

算法	准确率/%	召回率/%	精准率/%
卷积神经网络	89.6	86.2~94.1	87.2~93.7
循环神经网络	93.1	90.0~96.2	89.2~96.5
WiID	95.6	93.3~97.5	94.2~97.9

由表 1 可知,在准确率、召回率、精准率方面,WiID 算法识别效果均优于卷积神经网络和循环神经网络算法,结合两种算法,本文算法可以更有效地提取 CSI 数据步态特征,提高识别能力。

2.4.4 不同场景下的实验结果对比 为评估 WiID 算法的鲁棒性,即在不同场景下正确识别同一人的性能稳定性,实验分别设计了“正常情况”“改变穿着”“额外背包”“携带手提包”以及“偏离预定路径”5 种不同场景,并分别在每个场景下针对每位参与者各采集 30 组数据用于身份识别。表 2 给出了 6 名

参与者在不同场景下的平均识别准确率,其中“正常情况”是指训练数据的采集环境;在“改变穿着”的实验场景中,参与者们分别穿着薄 T 恤、羽绒服、带上帽子等不同于正常情况下的服饰;在携带配件的实验场景下,分别验证了“额外背包”和“携带手提包”两种不同情况对身份识别精度的影响;在“偏移预定路径”实验场景下采集测试数据时,要求参与者在偏离正常情况下预定路径 1 m 处行走。

表 2 不同场景下的平均识别准确率

实验场景	平均准确率/%
正常情况	95.6
改变穿着	95.0
额外背包	95.3
携带手提包	94.8
偏离预定路径	92.9

由表 2 可知,“改变穿着”“额外背包”“携带手提包”会不同程度降低平均识别准确率,但影响较小,降幅均控制在 0.8%以内;而“偏移预定路径”的实验场景下,由于路径偏移会影响信号的传播方式,因此平均准确率的降幅较为明显。总体来说,WiID 算法在人体装饰改变及路径小幅度偏离的情况下依然保持着稳定的身份识别准确率。

3 结 论

传统身份识别方法需要大量数据预处理工作,并且难以达到较高的准确率,而本文提出的 WiID 深度学习算法通过构建时空网络模型,自动提取 CSI 数据的空间和时间维度的特征,不仅摆脱了对手工编码特征的依赖,且具有较高的识别准确率,为端到端的非接触式身份识别提供了切实有效的实施途径。研究表明,基于深度学习的身份识别算法具有良好的鲁棒性,但需要充足的训练数据来保证识别效果;对于基于 Wi-Fi 的身份识别算法,被检测环境中人数的增加可能成为其提高准确率的障碍。

下一步工作将在现有工作基础上,提高算法在不同室内环境下身份识别的泛化能力,并探索其有效的识别范围,进一步提高身份识别性能。

参考文献:

[1] UNAR J A, SENG W C, ABBASI A. A review of biometric technology along with trends and prospects [J]. Pattern Recognition, 2014, 47(8): 2673-2688.
[2] CONNOR P, ROSS A. Biometric recognition by gait:

- a survey of modalities and features [J]. *Computer Vision and Image Understanding*, 2018, 167: 1-27.
- [3] WU Zifeng, HUANG Yongzhen, WANG Liang, et al. A comprehensive study on cross-view gait based human identification with deep CNNs [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2016, 39(2): 209-226.
 - [4] ZHANG Yuting, PAN Gang, JIA Kui, et al. Accelerometer-based gait recognition by sparse representation of signature points with clusters [J]. *IEEE Transactions on Cybernetics*, 2015, 45(9): 1864-1875.
 - [5] AL-NAIMI I, WONG C B, MOORE P, et al. Multi-modal approach for non-tagged indoor identification and tracking using smart floor and pyroelectric infrared sensors [J]. *International Journal of Computational Science and Engineering*, 2017, 14(1): 1-15.
 - [6] XIN Tong, GUO Bin, WANG Zhu, et al. Freesense: indoor human identification with Wi-Fi signals [C]// *Proceedings of the IEEE Global Communications Conference*. Piscataway, NJ, USA: IEEE, 2016: 1-7.
 - [7] ZENG Y, PATHAK P H, MOHAPATRA P. WiWho: WiFi-based person identification in smart spaces [C] // *Proceedings of the 15th International Conference on Information Processing in Sensor Networks*. Piscataway, NJ, USA: IEEE, 2016: 1-12.
 - [8] ZHANG Jin, WEI Bo, HU Wen, et al. Wifiid: human identification using WiFi signal [C]// *Proceedings of the International Conference on Distributed Computing in Sensor Systems*. Piscataway, NJ, USA: IEEE, 2016: 75-82.
 - [9] OHARA K, MAEKAWA T, MATSUSHITA Y. Detecting state changes of indoor everyday objects using Wi-Fi channel state information [J]. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2017, 1(3): 88.
 - [10] ALI K, LIU A X, WANG W, et al. Keystroke recognition using WiFi signals [C]// *Proceedings of the 21st Annual International Conference on Mobile Computing and Networking*. New York, USA: ACM, 2015: 90-102.
 - [11] CHO K, MERRIENBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation [EB/OL]. (2014-09-03) [2018-05-16]. <http://arxiv.org/abs/1406.1078>.
 - [12] 杨铮, 刘云浩. Wi-Fi 雷达: 从 RSSI 到 CSI [J]. *中国计算机学会通讯*, 2014, 10(11): 55-60.
YANG Zheng, LIU Yunhao. Wi-Fi radar: from RSSI to CSI [J]. *Communications of the CCF*, 2014, 10(11): 55-60.
 - [13] GOODFELLOW I, BENGIO Y, COURVILLE A, et al. Deep learning [M]. Cambridge, UK: MIT Press, 2016: 322-323.
 - [14] ZHANG Kai, ZUO Wangmeng, CHEN Yunjin, et al. Beyond a Gaussian denoiser: residual learning of deep CNN for image denoising [J]. *IEEE Transactions on Image Processing*, 2017, 26(7): 3142-3155.
 - [15] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C]// *Proceedings of the 32nd International Conference on Machine Learning*. New York, USA: ICML, 2015: 448-456.
 - [16] JOZEFOWICZ R, ZAREMBA W, SUTSKEVER I. An empirical exploration of recurrent network architectures [C]// *Proceedings of the 32nd International Conference on Machine Learning*. New York, USA: ICML, 2015: 2342-2350.
 - [17] ZAREMBA W, SUTSKEVER I, VINYALS O. Recurrent neural network regularization [EB/OL]. (2015-02-19) [2018-06-05]. <http://arxiv.org/abs/1409.2329>.
 - [18] 滕千礼, ESMAEILI KELISHOMI A, 蔡忠闽. 采用运动传感器的人体运动识别深度模型 [J]. *西安交通大学学报*, 2018, 52(8): 60-66.
TENG Qianli, ESMAEILI KELISHOMI A, CAI Zhongmin. A deep learning model for human activity recognition using motion sensor data [J]. *Journal of Xi'an Jiaotong University*. 2018, 52(8): 60-66.
 - [19] TOLIAS G, SICRE R, JEGOU H. Particular object retrieval with integral max-pooling of CNN activations [EB/OL]. (2016-02-24) [2018-06-05]. <http://arxiv.org/abs/1511.05879>.
 - [20] HALPERIN D, HU W, SHETH A, et al. Tool release: gathering 802.11n traces with channel state information [J]. *ACM SIGCOMM Computer Communication Review*, 2011, 41(1): 53-53.

(编辑 武红江)