

DOI:10.19651/j.cnki.emt.2212407

# 基于改进 LRCN 的人体运动识别方法<sup>\*</sup>

李嘉智 刘宁

(北京信息科技大学高动态导航技术北京市重点实验室 北京 100192)

**摘要:** 针对人体运动识别中数据特征提取不充分和识别准确率不高的问题,提出了一种改进长期循环卷积网络的人体运动识别模型。首先构建出一种由多层卷积神经网络和门控循环单元组成的 LRCN 模型。在此基础上构建内部和外部循环层,内部循环层作用是得到所选取时间窗内部时间特征和空间特征,外部循环层作用是从子序列数据中获取其所表征状态信息之间的特征相关性和时间相关性。提出的模型在 3 种公开数据集上验证,准确率均高于传统的 LRCN 模型,然后在自建数据集上进行测试验证,识别准确率为 99.7%。实验结果表明该模型在识别准确率上高于原始模型,验证了该模型的可行性。

**关键词:** 人体运动识别;传感器;门控循环单元;长期循环卷积网络

中图分类号: TP212 文献标识码: A 国家标准学科分类代码: 510.4

## Human motion recognition method based on improved LRCN

Li Jiazhī Liu Ning

(Beijing Information Science and Technology University, Technology Beijing Key Laboratory of High Dynamic Navigation Technology, Beijing 100192, China)

**Abstract:** Aiming at the problems of inadequate feature extraction and low recognition accuracy in human motion recognition, a human motion recognition model based on improved Long-term Recurrent Convolutional Network was proposed. Firstly, a LRCN model composed of multi-layer convolutional neural network and gated circulation unit is constructed. On this basis, the internal and external cycle layers are constructed. The role of the internal cycle layer is to obtain the internal time characteristics and spatial characteristics of the selected time window, while the role of the external cycle layer is to obtain the feature correlation and time correlation between the state information represented by the subsequence data. The proposed model was verified on three public data sets with higher accuracy than the traditional LRCN model. Then, it was tested and verified on the self-built data sets, and the recognition accuracy was 99.7%. The experimental results show that the recognition accuracy of this model is higher than that of the original model, which verifies the feasibility of this model.

**Keywords:** human motion recognition; sensor; gated cycle unit; long-term recurrent convolutional network

## 0 引言

近年来,随着模式识别技术的广泛应用,也促进了人体运动识别(human activity recognition, HAR)技术的快速发展,在日常生活中基于传感器的可穿戴设备成为研究热点,主要包括在外骨骼机器人<sup>[1]</sup>、救援抗灾<sup>[2]</sup>、体育训练<sup>[3]</sup>等领域。

传统的识别方法主要有机器学习中的朴素贝叶斯<sup>[4]</sup>、支持向量机<sup>[5]</sup>和随机森林等。由于传统的机器学习在提取特征的时候采用的是人工提取,依赖的是经验丰富的专家

进行设计改进,这种提取方式不仅工作量巨大、效率低下,设计的时候还具有一定的主观性,而且传统的机器学习算法处理的一般是线性相关的函数,但是当处理大量繁杂、非线性数据的时候,往往达不到预期的效果。神经网络的提出则很好的解决了这一问题,卷积神经网络(convolutional neural networks, CNN)和循环神经网络(recurrent neural network, RNN)分别在提取特征和时间序列方面具有独特的优势和性能,组合神经网络 CNN-LSTM 融合了两者网络的优势,极大的提高了识别的准确率。孙彦玺等<sup>[6]</sup>提出了一种融合卷积神经网络和双向长短期记忆网络的深度学

收稿日期:2022-12-16

\*基金项目:国家重点研发计划课题(2020YFC1511702)、北京市自然科学基金(4212003)、北京市科技新星计划交叉学科合作课题(202111)资助

习模型,在 DaLiAc 公开数据集上对 13 种人体活动的识别准确率达到了 97.7%,相对单一的长短期记忆网络(long short-term memory, LSTM)和双向长短期记忆网络(bi-directional long short-term memory, BiLSTM)网络有更好的识别分类效果。李浩等<sup>[7]</sup>提出了基于 CNN-Mogrifier LSTM 的运动识别算法,在自采集的人体行为数据集中准确率达到 98.18%。吴海涛等<sup>[8]</sup>提出了一种 CNN-GRU 模型,在人体行为识别数据集 OPPORTUNITY 上准确率分别达到了 94.186%,验证了模型有更好的准确度和稳定性。陈馨瑶等<sup>[9]</sup>提出了一种 CNN-BiLSTM 融合模型的方法,在 WISDM 数据集上对人体行为的 6 种动作识别准确率达到了 96.95%。周鹏等<sup>[10]</sup>建立一种深度卷积神经网络(DCNN),将时间序列转换成单通道行为图片,在行为识别数据集 UCI 上准确率达到了 97.05%。由此可知组合神经网络可以更充分的提取特征,并增强网络的泛化能力,有效的提高识别准确率,但这些 CNN-LSTM 组合模型方法都是对特征提取并处理,并没有考虑时间窗之间的相关联系。长期循环神经也是由 CNN 和 LSTM 构成,但是在卷积层中实用了时间包装器,有一些学者如 Cruz 等<sup>[11]</sup>使用长期循环卷积网络(long-term recurrent convolutional network, LRCN)进行眨眼检测,识别效果优于 CNN、LSTM 等结构,Liang 等<sup>[12]</sup>学者提出了一种具有注意力机制的长期循环卷积网络来检测暴力行为识别,与传统的 LRCN 相比提高了 10.5%。

综上所述,本文在此基础上提出了一种新的 Deep-LRCN 网络模型。本文在此原始 LRCN 的模型基础上使用门控循环单元(gate recurrent unit, GRU)网络替代 LSTM 以减少网络参数,并构建内部和外部循环层,内部循环层作用是得到所选取时间窗内部时间特征和空间特征,外部循环层作用是从子序列数据中获取其所表征的状态信息之间特征相关性和时间相关性,充分的提取数据信息,并在 3 种公开数据集和实验室自建数据集上进行测试验证,结果显示准确率都有明显提升,在自建数据集上准确率为 99.7%,验证网络具有良好的泛化能力。

## 1 神经网络模型系统框架设计

### 1.1 LRCN 和 DeepConvLstm 网络对比介绍

长期循环神经网络:LRCN<sup>[13]</sup>是 CNN 和 LSTM 相结合的一种网络架构,网络中使用了 TimeDistributed 包装器,该包装器的作用是将一个层应用到输入的每个临时片段,可以实现有序的端到端的结构处理方式,同时可以实现图片和行为的识别分类。LRCN 首先是利用卷积神经网络来提取数据片段的特征,然后把提取的特征输送到 LSTM 网络进行进一步的提取,这样就可以得到有效的人体动作的时序信息。LRCN 在经过 CNN 提取特征得到一个固定的输出向量,然后把这些输出向量送到 LSTM 中进行时序的提取运算,假设 LSTM 的神经元数目为  $w$ ,  $x_i$  表示输入

的数据,  $z_i$  表示为输入数据与其前一时刻的隐藏状态,  $h_{t-1}$  通过映射而产生的输出,  $h_t$  表示在此刻更新后的隐藏状态。那么 LRCN 的计算公式为:

$$h_1 = f_w(x_1, h_0) = f_w(x_1, 0) \quad (1)$$

$$h_2 = f_w(x_2, h_1) \dots h_T = f_w(x_T, h_{T-1}) \quad (2)$$

上述公式表示对 LRCN 模型中 LSTM 的神经元参数的累加,此时在  $t$  时刻下对结果  $y_t \in \mathbf{C}$  进行识别的公式如下所示,其中  $\mathbf{C}$  表示离散的有限类别的集合。

$$\hat{y}_t = W_z z_t + b_z \quad (3)$$

其中,  $W_z, b_z$  分别表示为 softmax 层的权重和偏置,  $z_t$  为 LSTM 的输出值。

最终的结果分类公式为:

$$P(y_t = c) = \text{softmax}(\hat{y}_t) \quad (4)$$

LRCN 并非是 CNN 和 LSTM 的直接拼接而成,由于卷积层中使用了 TimeDistributed 包装器,可以在不破坏时间序列结构和顺序的基础上对特征进行有序的提取,在完整的递归序列下学习特征来提高的预测精度,而 CNN-LSTM 在时间序列上的提取是乱序的。图 1 表示了 LRCN 和 DeepConvLstm(深度卷积神经网络)的结构差异。

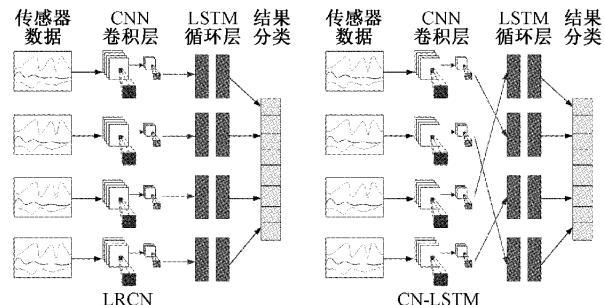


图 1 CNN-LSTM 和 LRCN 对比

Deep ConvLstm 深度神经网络由输入层、卷积层、LSTM 循环层和输出层组成。该模型充分利用了卷积神经网络提取特征的能力和长短时记忆网络获取时间序列的能力,在模型的多层融合中起到了很好的示范作用。该网络可以应用于不同的传感器(如加速度计、陀螺仪等),并可以将他们融合来提高识别精度。

### 1.2 本文网络模型

由上述介绍可知,LRCN 和 DeepConvLstm 都是由卷积神经网络和长短时记忆网络组成,但是又各有不同,考虑到两种模型的相关性和各自的优点,本文融合 LRCN 和 DeepConvLstm 各自的优点,提出一个改进的 Deep-LRCN 新网络模型。

本文提出的 Deep-LRCN 网络模型一共分为 3 部分,如图 2 所示,卷积池化层、内部循环层和外部循环层。其中卷积池化层在输入的时间轴方向做卷积操作来提取特征。内部循环层作用是处理 CNN 提取的特征映射结果,得到所选取时间窗内部的时间特征和空间特征,内部循环层只

能考虑到时间窗内部的时间序列相关性,无法联系到时间窗与时间窗之间的联系性,外部循环层作用是从子序列数据中获取其所表征的状态信息之间特征相关性和时间相关性,内部和外部循环层共同作用可更完全更充分的提取特征信息。

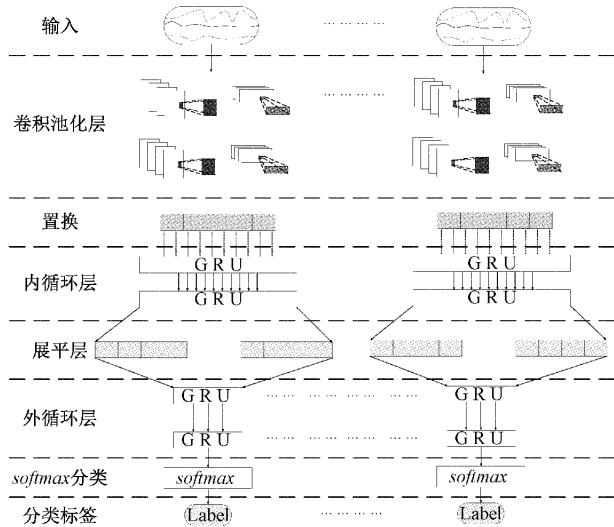


图 2 Deep-LRCN 网络模型

### 1.3 网络参数确定

#### 1) 卷积池化层参数设置

卷积池化层:本文提出的网络有 3 层卷积层和 2 层池化层,由于在提取数据时按照滑动时间窗的方式,所以本文采用二维卷积网络。在确定卷积核的数量时,本文测试了 16、32、64 和 128 个卷积核数量,在测试时验证卷积核在 64 时,效果最佳,继续增大到 128 或更高时,准确率相较于卷积核 64 持平,损失值的收敛速度相较于卷积核为 64 来说略快,但是参数成倍数增多,每轮训练时间大幅增加,所以最终卷积核数量确定为 64,卷积核大小为 3,在每个卷积层中数量和大小都是相同的,这样的好处的是可以从原始数据中学习到更多类型的非线性数据,实验结果具体如图 3 所示。卷积层中的激活函数为 RELU。池化方式分为最大池化和平均池化 2 种,最大池化是采用窗口内的最大值,而平均池化采用的窗口内的平均值,为了提取到数据集中的最显著的特征,本文使用的是最大池化方式,池化的滤波器大小为 2,步长为 2。

#### 2) 循环层参数设置

由于 CNN 提取特征每一段都是独立的,没有考虑数据段之间的联系性。而循环神经网络的优势在于捕捉时间尺度上的依赖关系,通过前一时刻和后一时刻的状态来更加精准的判断出当前时刻的状态。GRU<sup>[14]</sup>是 LSTM 网络优化的一种变体网络,也是为了解决长期记忆和反向传播中的梯度问题而提出的。相对 LSTM 来说,它的作用效果相当,网络结构却更简单,参与运算的参数也更少,运算时占用的内存更少,速度也更快。在 GRU 网络中,只有更新

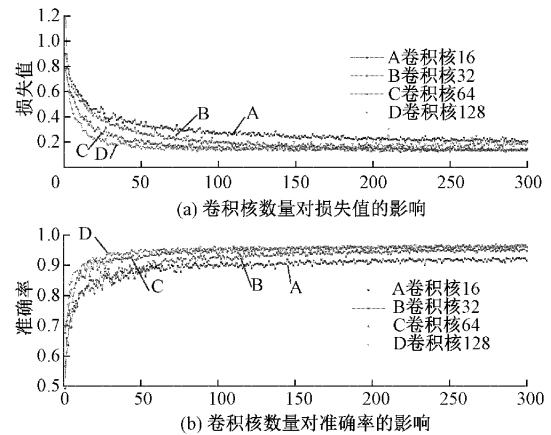


图 3 卷积核数量对损失值和准确率的影响

门和重置门,更新门的作用是控制前一时刻的信息传递到当前时刻的程度,其值越大,表示被传递带入的信息越多。重置门的作用是控制前一时刻的状态信息有多少被写入当前时刻中,其值越小,表示写入的信息越少。其单元结构如图 4 所示。

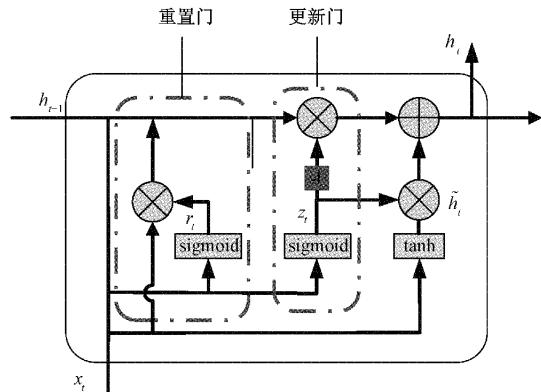


图 4 GRU 单元结构图

GRU 最重要的一个步骤就是“更新记忆”阶段,假设 GRU 在时间  $t$  时的隐藏状态为  $h_t$ ,那么可由  $t-1$  时刻的隐藏状态  $h_{t-1}$  和待定的隐藏状态  $\tilde{h}_t$  表示为:

$$h_t = (1 - z_t) \times h_{t-1} + z_t \times \tilde{h}_t \quad (5)$$

$z_t$  表示更新门,其更新的程度可用公式表示为:

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \quad (6)$$

$\tilde{h}_t$  隐藏状态的表达式为:

$$\tilde{h}_t = \tanh(W_{\tilde{h}} \cdot [r_t \cdot h_{t-1}, x_t]) \quad (7)$$

重置门  $r_t$  的计算方式为:

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (8)$$

其中,  $\sigma$  表示 sigmoid 激活函数。

以训练的 WISDM 数据集为例,在相同的环境下,在循环层用控制变量法对比 LSTM 和 GRU,实验结果如图 5, LSTM 为循环层时迭代 50 次左右损失函数收敛,而 GRU 为循环层时迭代 20 次左右即可收敛,并且准确率和 LSTM

相持平。所以在网络中本文考虑用 GRU 网络来代替 LSTM 来执行循环体部分的功能。GRU 循环层的神经元数量为 32。

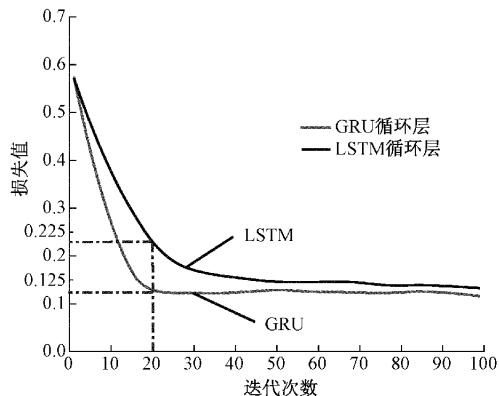


图 5 GRU 和 LSTM 损失函数收敛性比较

表 1 LSTM 和 GRU 参数对比

循环层	单层参数	单次训练时间/s	准确率/%
LSTM	49 408	10	95.5
GRU	37 248	8	95.6

内部 BIGRU: 内部有 2 层 BIGRU, 本文测试神经元的数量为 32、64、72 和 128, 结果显示为 64 时效果最佳。这 2 层 GRU 的作用是处理卷积网络处理后特征映射结果, 经过这 2 层的 GRU 后, 捕捉时间窗之间的联系, 输出其内部时间和空间特征。

外部 GRU: 外部是 2 层 GRU, 神经元数量为 64, 输入为内部 GRU 的输出结果, 外部 GRU 的作用外部循环层作用是从子序列数据中获取其所表征的状态信息之间特征相关性和时间相关性, 最终将得到的结果输送给 softmax 以得到最终的分类结果。其中在内部和外部循环层之间还有一层展平层。

另外本文使用批量标准化层 (batch normalization, BN)<sup>[13]</sup> 来替代卷积层中的 Dropout。BN 可以通过一定的规范化方法, 使每层的神经网络的输入值参数的分布强行拉回到均值为 0, 方差为 1 的标准正态分布, 可以有效的避免梯度消失的问题, 加快训练的速度, 训练更为稳定。此外 BN 相对 Dropout 来说对卷积的正则化作用更大, 在一定程度上还可以防止过拟合。综上所述, 使用 BN 替代 Dropout 可以使网络具有更好的泛化能力。

## 2 实验结果与分析

实验环境: 电脑 wisdom10 系统, CPU 型号为 Intel(R) Core(TM) i7-10750H, 内存为 16 G, GPU 为 NVIDIA GeForce GTX 1650, 使用的算法是在机器学习的 TensorFlow 框架上实现的。在对数据集样本训练时, 使用的优化器是 ADMA, 学习率设置为 0.001。

### 2.1 公开数据集验证

WISDM 数据集: 该公开数据集的传感器为手机内置的加速度计传感器, 采样频率是 20 Hz。采样时手机放置在受试者的腿部, Z 轴采集腿部的运动方向, Y 轴采集上下方向, X 轴捕捉的是腿部的水平方向。数据集中包括了步行、慢跑、上楼、下楼、站立、坐下 6 种动作。

UCI HAR 数据集: 该数据集是由 30 名年龄在 19~48 岁之间的志愿者组成, 加速度计和陀螺仪传感器放置在受试者的腰部, 共采集 12 个动作, 采样频率是 50 Hz, 在本文实验验证中采用其中的 6 种动作: 坐、站、躺、上楼、下楼、走路。这些数据集中 70% 的志愿者的数据用作训练集, 30% 的志愿者数据用作测试集。

PAMAP2 数据集: 该数据集采集的是 8 位男性和 1 位女性, 采用 3 个惯性器件磁力计、陀螺仪、加速度计和一个心率检测器, 3 个传感器分别放置在胸部、主导臂的手腕处, 和主导腿的脚踝上。年龄在 27~34 岁之间, 每位志愿者都按照要求完成 12 项动作, 其中一些简单的动作如平躺、站立和行走和复杂的动作如跳绳、折叠衣服和开车。在本文的测试中, 主要使用其中的 9 种动作进行测试。样本划分为 70% 的训练集和 30% 的测试集。

在此环境下对 3 个数据集进行训练, 选取最终稳定后的结果, 其准确率如图 6 所示。

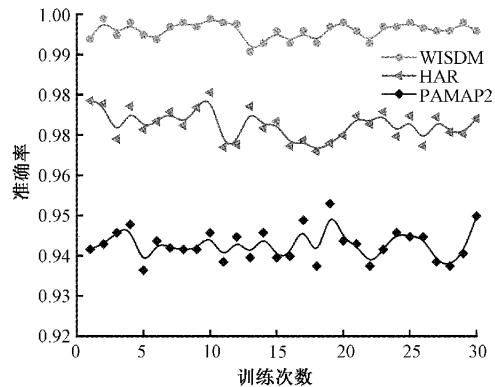


图 6 3 种数据集在 Deep-LRCN 下的准确率

混淆矩阵是一种可视化的用来呈现算法性能的矩阵, 又称为错误矩阵或可能性表格。主要用于显示分类结果, 图 7~9 为 3 种数据集的混淆矩阵。

混淆矩阵包含了数据集中的对动作准确率的预测信息和真实动作准确率的信息。由混淆矩阵可知, 本文提出的模型在不同的数据集上对不同的动作的预测取得了良好的效果。在 WISDM 中对 6 种动作的预测较为准确, 在 UCI HAR 的混淆矩阵中可知对动作‘静坐’和‘站立’的预测准确率较低, 是由于坐和站动作较为相似, 仅存在 Z 轴加速度上数据的不同。PAMAP2 中对‘上楼’和‘下楼’的识别准确率较低, 这也是由于‘上楼’和‘下楼’在加速度计、陀螺仪等数据上有一定的相似性, 虽然有个别动作的识别准确率相对较低, 但是总体而言效果还是令人满意的。

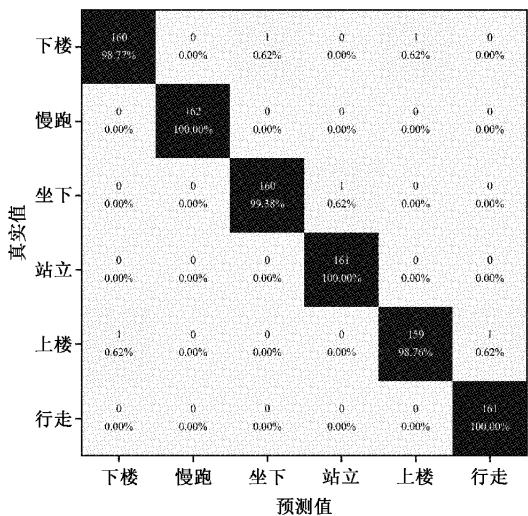


图 7 WISDM 的混淆矩阵

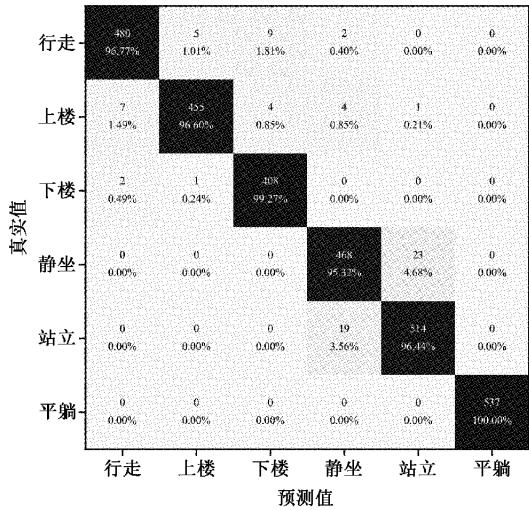


图 8 UCI HAR 的混淆矩阵

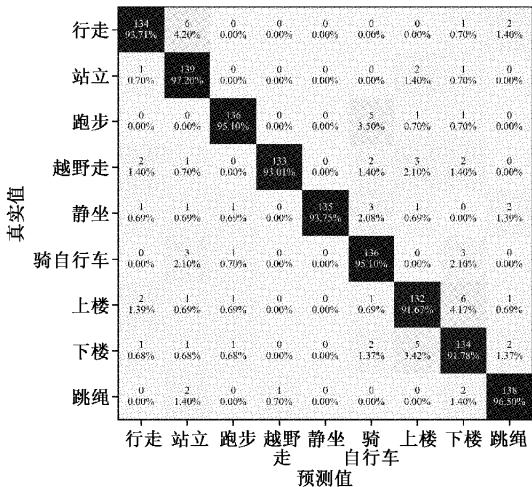


图 9 PAMAP2 的混淆矩阵

## 2.2 不同网络模型结果对比

为了严格对比网络的优缺点,本文对比了其他网络结构。在 WISDM 数据集上本文提出的网络模型的准确率达到了 99.48%,和文献[16]使用的 DeepConvLstm 模型相比,提高了 0.98%;和文献[9]CNN-BILSTM 模型相比提高了 2.53%。在 UCI HAR 数据集上本文的准确率达到了 97.46%,相较于文献[16]提高了 3.61%,相较于文献[10]深度卷积神经网络(DCNN)提高了 0.41%。并在 PAMAP2 数据集上进行测试,用控制变量使两种网络在参数上保持参数一致,仅网络结构不同,在 LRCN 网络上的准确率为 88.7%,在 DeepConvLstm 上的准确率为 91.62%,在本文提出的网络中测试准确率为 94.20%,相对 LRCN 提高了 5.5%,相对 DeepConvLstm 提升了 2.85%。

表 2 不同网络模型下的准确率对比

数据集	LRCN	DeepConvLstm	其他组合模型		本文模型
			模型	准确率	
WISDM	97.5	98.50 <sup>[16]</sup>	96.95 <sup>[9]</sup>	99.48	
UCI HAR	92.3	93.85 <sup>[16]</sup>	97.05 <sup>[10]</sup>	97.46	
PAMAP2	88.7	91.62	—	94.20	

## 2.3 自建数据集验证

为了进一步验证网络结构的可靠性和泛化性,实验室征集了年龄在 22~26 岁之间的 10 名男性和 2 名女性,使用六轴 IMU(加速度计和陀螺仪)采集加速度和角速度,采样频率为 50 Hz。采集了包含走、跑、跳、蹲、蹲走、躺 6 种动作的数据集,各种动作的样本数量经过修整后共有 349 958 组数据,其中总量的 70% 用来训练,30% 用来测试。其中行走数据为 93 959,跑步为 65 735,跳为 51 232,跨步为 44 325,蹲为 54 372,蹲走为 40 335。

在相同的网络模型下对自建数据集进行验证,验证结果如下,识别准确率总体达到了 99.7%,损失函数收敛速度也很快,在训练 20 轮左右即可完全收敛。6 种动作均可准确的识别。图 10 为自建数据集的训练结果。

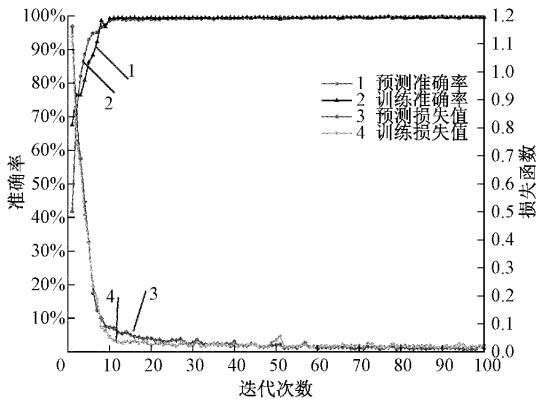


图 10 自建数据集训练结果

图 11 为自建数据集所对应的混淆矩阵。

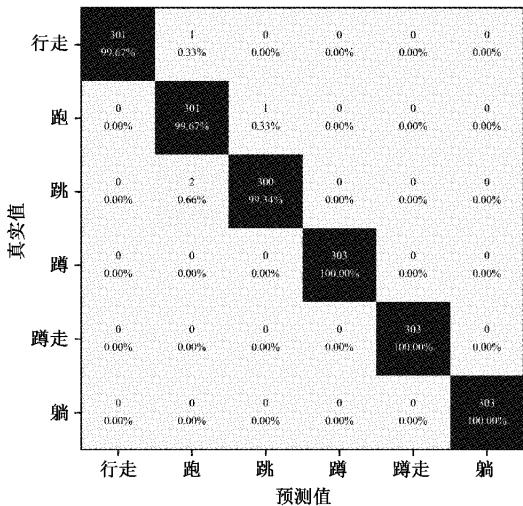


图 11 自建数据集混淆矩阵

表 3 为具体评估指标。评估指标为准确率(Accuracy)、精确率(Precision)、召回率(Recall)和 F1 分数。

表 3 自建数据集评估指标

活动类型	准确率	精确率	召回率	F1 分数
走	0.99	1.00	0.99	0.99
跑	0.99	0.99	0.99	0.99
跳	0.99	0.99	1.00	0.99
蹲	1.00	1.00	1.00	1.00
蹲走	1.00	1.00	1.00	1.00
躺	1.00	1.00	1.00	1.00

准确率:模型中预测的正确数量与样本总数之比。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$

其中,  $TN$  为将负类预测为负类数,  $FN$  为将正类预测为负类数(漏报),  $TP$  为将正类预测为正类数,  $FP$  为将负类预测为正类数(误报);

精确率:模型正确的正类预测数与正类预测总数之比。

$$Precision = \frac{TP}{TP + FP} \quad (10)$$

召回率:模型正确的正类预测数与样本正类总数之比。

$$Recall = \frac{TP}{TP + FN} \quad (11)$$

F1 分数:精度和召回率的加权调和平均,当 F1 较高时则能说明实验方法比较有效。

$$F1 Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (12)$$

### 3 结 论

结果显示本文提出的模型在 3 个公开数据集和实验室

自建数据集上取得了良好的识别效果。其中 WISDM 和 UCI HAR 的识别率均高于文献[9]、[10]和[16]的结果,并在 PAMAP2 数据集上进行对比测试,本文提出的 Deep-LRCN 网络模型相较于传统的 LRCN 模型识别准确率有明显的提高。并且自建数据集的识别准确率和损失函数均有良好的表现,这表明模型具有良好的泛化性,并更加证明了深度组合神经网络的优点和具有更广阔的应用范围。

本文提出了一个融合了 LRCN 和 DeepConvLSTM 各自优点的改进 Deep-LRCN 网络模型,该模型最大的特点是在 LRCN 的基础上构建出内层和外层循环层,尽可能地捕捉到时间窗口和特征之间的联系,为人体行为的预测提供更详细的特征,此外还在网络结构中使用 GRU 来替换 LSTM 减少参数和计算时间,虽然内层和外层循环层的设置使得特征提取变得充分、准确率得到提高,但是同时也使得网络结构体积变大,这也是后续改进的方向。本文提出的模型在人体行为识别的数据集上取得了较好的结果,在以后的工作中,考虑建立更庞大数据集,采集更多种类的非规则动作,调整和完善网络结构。

### 参考文献

- [1] 高经纬,马超,姚杰,等. 基于机器学习的人体步态检测智能识别算法研究[J]. 电子测量与仪器学报, 2021, 35(3): 49-55.
- [2] ZHANG Y, GUO Q. A human action recognition algorithm in dynamic scene of emergency rescue, virtual [C]. Institute of Electrical and Electronics Engineers Inc(CCET4), 2021; 12-16.
- [3] 刘志鹏. 面向体育训练的人体姿势实时识别研究[J]. 闽南师范大学学报(自然科学版), 2022, 35(1): 115-120.
- [4] 董宁,房芳,马旭东. 一种基于动态贝叶斯网络的人体动作识别方法[J]. 工业控制计算机, 2020, 33(3): 12-14.
- [5] 王晋. 基于压力传感器及支持向量机的人体运动识别系统[J]. 电子设计工程, 2018, 26(18): 92-95, 101.
- [6] 孙彦玺,陈继斌,武东辉. 基于卷积神经网络-双向长短期记忆网络的人体活动识别方法[J]. 科学技术与工程, 2022, 22(4): 1517-1525.
- [7] 李浩,于志远,尹业成,等. 基于 CNN-Mogrifier LSTM 的人体运动模式识别算法[J]. 电子测量技术, 2021, 44(21): 95-100.
- [8] 吴海涛,陆志平,胡晨骏. 混合神经网络模型在人体活动识别中的研究[J]. 计算机应用与软件, 2021, 38(8): 187-193, 219.
- [9] 陈馨瑶,张天荣,朱雪芬,等. 基于融合模型的人体行为识别方法[J]. 传感器与微系统, 2021, 40(1): 136-139, 143.
- [10] 周鹏,袁国良,张颖,等. 基于改进的 DCNN 人体行为识别[J]. 传感器与微系统, 2021, 40(10): 125-128.

- 
- [11] CRUZ G, LIRA M, LUACES O, et al. Eye-LRCN: A long-term recurrent convolutional network for eye blink completeness detection[J]. IEEE Transactions on Neural Networks and Learning Systems, 2022;1-10, DOI:10.1109/TNNLS.2022.3202643.
  - [12] LIANG Q, LI Y, YANG K, et al. Long-term recurrent convolutional network violent Behaviour recognition with attention mechanism [J]. MATEC Web of Conferences, 2021(336):05013-05019.
  - [13] DONAHUE J, HENDRICHES L, ROHRBACH M. Long-term recurrent convolutional networks for visual recognition and description[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 677-691.
  - [14] CHUNG J, CAGLAR G, KYUNG C, et al. Gated feedback recurrent neural networks[J]. CoRR, 2015, 2067-2075.
  - [15] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[J]. JMLR.org, 2015, 37(1):448-456.
  - [16] 王震宇, 张雷. 基于深度卷积和门控循环神经网络的传感器运动识别[J]. 电子测量与仪器学报, 2020, 34(1):1-9.

#### 作者简介

- 李嘉智,硕士研究生,主要研究方向为深度学习,室内定位和导航。  
E-mail:1609617665@qq.com
- 刘宁(通信作者),博士,研究员,主要研究方向为高动态谐振陀螺、惯性器件和导航方法。  
E-mail:ning.liu@bistu.edu.cn