

# 基于混合空洞卷积 CNN 和 BiGRU 的表面肌电信号手势识别

张凯 陈峰

(南通大学电气工程学院 江苏南通 226019)

**摘要** 针对基于表面肌电信号(sEMG)的手势识别准确率低、计算量大的问题,提出一种基于混合空洞卷积神经网络组合双向门控循环单元与注意力机制(HDC-BiGRU-Attention)的表面肌电信号手势识别方法。相比普通CNN,HDC通过设置奇偶混合且大小不同的膨胀率,可以扩大感受野,减少过拟合,提取到更多特征。BiGRU模块能很好地提取和处理数据的时序特征,Attention模块为重要特征赋予更大的权重,可以提高准确率。在NinaproDB1数据集和自采数据集上分别实现92.72%和97.85%的准确率。

**关键词** 表面肌电信号 手势识别 混合空洞卷积 双向门控循环单元 Attention 机制

中图分类号 TP391.4

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.11.031

## SURFACE EMG SIGNAL GESTURE RECOGNITION BASED ON HYBRID DILATED CONVOLUTION CNN AND BIGRU

Zhang Kai Chen Feng

(College of Electrical Engineering, Nantong University, Nantong 226019, Jiangsu, China)

**Abstract** Aimed at the problem of low accuracy and large amount of calculation for gesture recognition based on surface electromyography (sEMG), a method for sEMG gesture recognition based on a hybrid dilated convolutional neural network combining bidirectional gated recurrent unit and attention mechanism is proposed. Compared with the ordinary CNN, HDC can expand the receptive field, reduce over-fitting, and extract more features by setting the dilation rate to parity hybrid and different sizes. The BiGRU module can extract and process the timing features of the data well, and attention module gives greater weight to important features, which can improve accuracy. The accuracy rates of 92.72% and 97.85% were achieved on the NinaproDB1 dataset and the self-acquisition dataset, respectively.

**Keywords** sEMG Gesture recognition Hybrid dilated convolution BiGRU Attention mechanism

## 0 引言

表面肌电信号(sEMG)是一种生物电信号,存在于肌肉神经。当大脑下达肌肉动作指令,肌肉会产生控制信号,可以通过相关设备采集到这种电信号。肌电信号的识别研究对于脑卒中患者的恢复治疗有着重要的应用。通过采集患者的肌电信号进行识别可以控制设备进行牵引代替传统医师手动牵引,在可穿戴式外骨骼上也有着重要应用,可通过对肌电信号的识别控制外骨骼的动作。

在肌电信号识别方面一般应用SVM、BP神经网络等传统方法。近年来,深度学习获得了更好的应用效果。文献[1]提出基于深度学习的领域自适应框架来增强基于表面肌电信号手势识别,并在NinaPro、CSL-HDEMG和自采集的CapgMyo数据集上进行实验。文献[2]基于Antonyan Vardan变换(aVT)的随机滤波器结合R-ELM和R-Regularized ELM(RELM),从系统导出可靠性度量,自动选择最可靠的样本进行信号分类。文献[3]建立了Ninapro数据集并采用LS-SVM方法进行分类。文献[4]采用长短时记忆与卷积神经网络结合的方法进行手势分类识别。文献[5]引入了高密度

表面肌电信号在空间上组成的表面肌电信号图像的概念,并通过基于深度卷积网络分类方案的手势识别。文献[6]使用混合空洞卷积(HDC)应用于图像补全实验。文献[7]通过卷积神经网络以多肌电特征图像为输入进行手势识别在 NinaproDB1 数据集上取得了 90% 以上的准确率。文献[8]通过迁移学习技术增强卷积神经网络,实现了 97% 以上的准确率。文献[9]通过深度卷积神经网络自动提取特征实现取代传统方法使用的人工特征提取,用于对手部假肢的控制。文献[10-11]同样通过卷积神经网络使用 Ninapro 数据集对超过 50 次手部运动进行了卷积网络分类测试。文献[12]将时域内相邻数据进行叠加,增强输入矩阵中相邻元素之间的时间相关性。利用 LeNet-5 网络,使用 NinaDB1 数据集进行肌电信号分类。文献[13]通过卷积神经网络对肌电信号进行分类实现对机械手的控制实验。文献[14]通过循环神经网络(RNNs)实现对肌电信号手势的在线分类。

循环神经网络及其改进网络(LSTM)和门控循环单元(GRU)在时序处理方面性能优异,在文本翻译、语义识别和语音识别等方面得到了很好的应用,在肌电信号和心电信号(ECG)识别等方面也有优秀的表现。文献[4]采用长短时记忆网络与卷积神经网络的组合模型进行肌电信号的手势识别实验,取得了很好的效果。文献[15]使用膨胀卷积和门控循环单元的组合模型,在网络入侵检测识别实验中取得高达 99% 以上的准确率。文献[16]通过 LSTM 神经网络对单通道肌电信号进行识别实现了比传统 SVM 分类器更高的准确率。文献[17]通过双向 GRU 和双向 Attention 机制对中文文本人物关系的抽取进行实验并取得良好的效果。文献[18]采用基于 CNN 和 GRU 的模型对心电信号分类实现 99% 以上的准确率。文献[19]采用基于 CNN 和 BiGRU 的方法对心律异常进行自动判别,实现最高 99% 的准确率。文献[4,20-22]等结合 Attention 机制方法,在机器翻译、肌电信号识别和心电信号识别等方面取得了良好的实验效果。

## 1 数据处理

### 1.1 数据集

本文实验采用公共数据集 Ninapro。该数据集数据量大,采集的动作丰富,每个单位数据集里面包括表面肌电信号、加速度计、手部运动学和动态数据等,记

录了 67 名完整受试者和 11 名进行了至少 50 次手部运动的截肢者的数据。

NinaproDB1 数据集包括 27 名完整的受试者(7 名女性和 20 名男性,其中 2 个左手和 25 个右手)的肌电信号。本次采用 DB1 数据集的第一位受试者的肌电信号进行实验,采集频率 100 Hz。图 1 所示为该数据集的 52 种手势动作示意图。




图 1 手势动作示意图

### 1.2 信号预处理

NinaproDB1 数据集采集频率为 100 Hz,采集设备带有 50 Hz 工频滤波,所以,这里再对数据集进行 1 阶 1 Hz 巴特沃斯低通滤波以减少噪声信号。图 2 为一段信号滤波前后对比图。可以看出滤波后的信号噪声减少,高频信号被很好地滤除。




图 2 滤波前后信号比较

## 2 网络模型

### 2.1 混合空洞卷积神经网络(HDC)

空洞卷积(Dilated Convolution)又称膨胀卷积,空洞即在卷积核元素间加入空洞,可实现在不增加参数

量的前提下扩大感受野。相较普通 CNN,可降低网络深度,减少过拟合。用膨胀率  $d$  表示膨胀程度,当膨胀率  $d=1$  时,表示普通卷积过程。假设一个  $3 \times 3$  的卷积核,膨胀率  $d$  设为 2,那么膨胀前后卷积核大小如图 3 所示。




图 3 膨胀率为 2 的卷积核

膨胀后,卷积核仍为  $3 \times 3$ ,为方便理解,把膨胀后的卷积核大小看作  $5 \times 5$ ,空洞表示 0。膨胀后的卷积核和感受野分别用式(1)和式(2)表示。

$$k_d = k_l + (k_l - 1) * (d - 1) \quad (1)$$

$$F_m = F_{m-1} + ((k_d - 1) * \prod_{i=1}^{m-1} s_i) \quad (2)$$

式中: $k_d$  为膨胀后的卷积核; $k_l$  为膨胀前的卷积核; $d$  为膨胀率; $F_{m-1}$  为膨胀前第  $m-1$  层感受野; $F_m$  为膨胀后的第  $m$  层感受野; $s_i$  为第  $i$  层的卷积移动步长。

对于一维输入信号,可用式(3)表示空洞卷积。

$$O(t) = \sum_{h=1}^H f[t + dh] * k(h) \quad (3)$$

式中: $O$  为卷积后的输出; $f$  为输入; $t$  为卷积核的大小; $k$  为卷积核; $H$  为卷积核的上限; $h$  为卷积核的下限; $d$  为膨胀率。

单一的膨胀率将导致很多数据无法被应用到,信息受到很大损失,这种现象称为栅格效应。混合空洞卷积(Hybrid Dilated Convolution, HDC)叠加的膨胀率不能有大于 1 的公约数,可以避免产生栅格效应,堆叠多层还可以提取到更多的数据特征。图 4 为膨胀率为 1、2 和 5 的混合空洞卷积。




图 4 混合空洞卷积示意图

图 5 为一维混合空洞卷积的示意图,卷积核大小为 3,膨胀率  $d$  分别为 1、2 和 3。在信号处理方面一维混合空洞卷积通过多层的堆叠同样具有扩大感受野、减少计算量和保留更多原始数据特征的特点,具有很好的效果。




图 5 一维混合空洞卷积示意图

## 2.2 双向门控循环单元(BiGRU)

GRU 是 RNN(循环神经网络)的一种改进,可以更好地提取信号的时序特征,在信号识别上有很好的效果,也为梯度爆炸和梯度消失提供了很好的解决方法。与 LSTM(长短时记忆模型)的三个门相比 GRU 只有重置门和更新门两个门控,结构更简单,处理效果不输 LSTM。重置门决定了如何将新的输入信息与前面的记忆相结合,更新门定义了前面记忆保存到当前时间步的量。两个门共同根据前后数据相关性决定该模块的输出,其单元结构示意图如图 6 所示。




图 6 GRU 单元示意图

重置门、更新门、候选状态和当前时刻状态可分别用如式(4)、式(5)、式(6)和式(7)表示。

$$r_t = \sigma(W_r * [h_{t-1} \ x_t] + b_r) \quad (4)$$

$$z_t = \sigma(W_z * [h_{t-1} \ x_t] + b_z) \quad (5)$$

$$\tilde{h}_t = \tanh(W_{\tilde{h}} * [r_t \cdot h_{t-1} \ x_t] + b_{\tilde{h}}) \quad (6)$$

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t \quad (7)$$

式中:“ $*$ ”为矩阵相乘;“ $\cdot$ ”为矩阵对应元素相乘; $z_t$  为门控信号,其值为  $0 \sim 1$ ,当  $z_t = 1$  表示完全保留上一时刻隐藏状态,当  $z_t = 0$  表示完全不保留, $z_t$  越接近 1 上一时刻隐藏状态保留的越多; $W_r$ 、 $W_z$  分别表示重置门和更新门的权重参数矩阵; $b_r$ 、 $b_z$  分别表示重置门和更新门的偏差矩阵; $x_t$  为当前时刻的输入; $h_{t-1}$  为上一时刻隐藏状态; $W_{\tilde{h}}$  为候选状态的权重参数矩阵; $b_{\tilde{h}}$  为候选状态的偏差矩阵; $\sigma$  为 Sigmoid 激活函数。

本文采用的双向 BiGRU 单元示意图如图 7 所示。

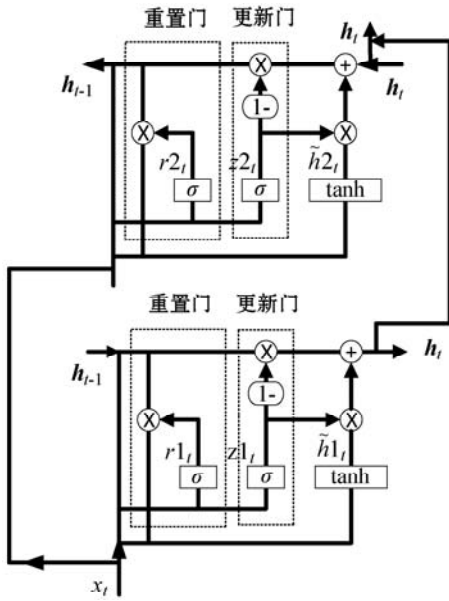


图 7 双向 GRU 单元示意图

BiGRU 具有前向和后向两个方向的传播功能,可以提取到当前时刻数据与前后向时刻数据的相关性特征,可以提高准确率。

从图 8 可以看出双向 GRU (BiGRU) 和双向 RNN 相似由两个单向的 GRU 单元组成,分别负责前向传播和后向传播。当前时刻的输入  $x_t$  会分别输入给前后两个方向的 GRU 单元,通过正向和反向两个单元输出结果来综合决定输出。




图 8 双向 GRU 网络结构示意图

BiGRU 网络工作过程主要包括前向隐层计算、后向隐层计算、隐藏层计算和输出计算。

前向隐藏状态  $\vec{h}_t$  可用如式表示:

$$\vec{h}_t = \sigma(X_t W_1^{(f)} + \vec{h}_{t-1} W_2^{(f)} + b^{(f)}) \quad (8)$$

后向隐藏状态  $\overleftarrow{h}_t$  可用式(9)表示。

$$\overleftarrow{h}_t = \sigma(X_t W_1^{(b)} + \overleftarrow{h}_{t-1} W_2^{(b)} + b^{(b)}) \quad (9)$$

将前后隐藏状态按元素相加进行连结后得到隐藏状态  $h_t$ ,用式(10)表示输出  $O_t$ 。

$$O_t = h_t W_o + b_o \quad (10)$$

式中: $\vec{h}_t$ 、 $\overleftarrow{h}_t$  分别表示当前时刻前向和后向隐藏状态;

$\vec{h}_{t-1}$ 、 $\overleftarrow{h}_{t-1}$  分别表示上一时刻前向和后向隐藏状态; $X_t$  表示输入, $W_1^{(f)}$ 、 $W_2^{(f)}$ 、 $W_1^{(b)}$ 、 $W_2^{(b)}$  表示前向和后向传播对当前时刻输入和上一时刻上输入的权值矩阵; $b^{(f)}$ 、 $b^{(b)}$  表示前向和后向传播的偏差矩阵; $h_t$  表示连结后的隐藏状态; $O_t$  表示输出; $W_o$ 、 $b_o$  分别表示决定输出的输出层权值矩阵和偏差矩阵;“ $\rightarrow$ ”、“ $(f)$ ”表示前向传播层,“ $\leftarrow$ ”、“ $(b)$ ”表示后向传播层。

### 2.3 注意力机制

注意力机制(attention 机制)是一种模仿人类大脑对事物的重点分析机制的方法,在自然语言处理和计算机视觉的神经模型方面有着重要的应用。在注意力机制中模仿人类大脑,对于重要的特征重点关注,即得到较大的权重,不重要的特征将得到较小的权重。通过这种按照特征重要程度获取权重的方式可以减少不必要的特征的数量,提高效率,同时重要的特征被重点关注,将大大提高分类准确率。可用式(11) - 式(13)表示该方法的计算过程。

$$u_t = \tanh(W_w h_t + b_w) \quad (11)$$

$$\alpha_t = \frac{\exp(u_t^T u_w)}{\sum_t \exp(u_t^T u_w)} \quad (12)$$

$$s_t = \sum_t \alpha_t h_t \quad (13)$$

式中: $h_t$  表示注意力机制模块输入,来自上一层提取的特征输出,这里来自 BiGRU 模块的输出; $u_t$  表示  $h_t$  经过权重矩阵  $W_w$  和偏差矩阵  $b_w$  的操作后得到的结果; $\alpha_t$  表示本来的隐藏层在新的隐藏层中所占权重比重,作为获取的原特征的权重; $s_t$  表示原特征和获取的权重相乘作为新的特征,即注意力机制模块的输出。

### 2.4 混合空洞卷积-双向门控循环单元-注意力机制模型

混合空洞卷积与 BiGRU 结合实现了网络深度的增加。该模型通过卷积模块提取出肌电信号中的特征送入到 BiGRU 网络进行下一步处理,BiGRU 可以更好地提取时序特征,BiGRU 网络的输出作为注意力机制模块的输入,注意力机制根据输入的特征的重要性赋予特征不同的权重,最后将特征送入 Softmax 中进行手势动作的分类。该模型结构如图 9 所示。




图 9 本文模型结构示意图

该模型包括输入和输出层、3 个卷积层、一个 Maxpooling 池化层、3 个 Fullconnection 全连接层、一个 BiGRU 模块层、一个 Attention 模块和一个 Softmax 层。只在卷积模块后添加 Maxpooling 层是因为采用的数据集属于稀疏数据集，且数据分割后输入数据尺寸比较小，若采用多次池化将损失大量数据特征，故只在卷积模块后添加一次 Maxpooling 最大池化层。

表 1 所示为本文模型部分主要参数设置情况。

表 1 模型部分参数

层名	尺寸	参数
膨胀卷积层 1	1 × 3	32
膨胀卷积层 2	1 × 5	64
膨胀卷积层 3	1 × 11	64
Maxpooling 层	5 × 2	1
Fullconnection1 层	—	256
BiGRU 层	—	64
Attention 层	—	1
Fullconnection2 层	—	128
Fullconnection3 层	—	52
Softmax 层	—	—

### 3 实验与结果分析

#### 3.1 实验方法

将公共数据集 NinaproDB1 的 1、3、4、6、8、9 和 10 次数据作为此次实验的训练集，把 2、5 和 7 次作为测试集，以便于与采用相同数据集的方法进行对比。根据调试结果选择 Batch\_size 为 512，epoch 为 30。

将滤波后的数据按照窗口重叠法进行分段，选择滑动窗口 200 ms，滑动步长为 50 ms，重叠部分 150 ms。以一段数据为例，信号分割过程如图 10 所示。100 Hz 的采样率，分段后每段数据大小为 10 × 20，将分段后的数据送入模型。




图 10 信号分割示意图

图 11 为本文方法的机器学习流程。对数据处理后将训练集导入模型进行训练，并通过 SGD 优化。收敛后保留参数并加载测试集进行实验。堆叠 3 层膨胀率分别为 1、2 和 5 的空洞卷积提取信号特征，初始卷

积核为 1 × 3 × 32，经过后面两层膨胀率为 2 和 5 的膨胀，得到卷积核尺寸分别为 1 × 5 × 64、1 × 11 × 64，选择 ReLU 作为每层激活函数。

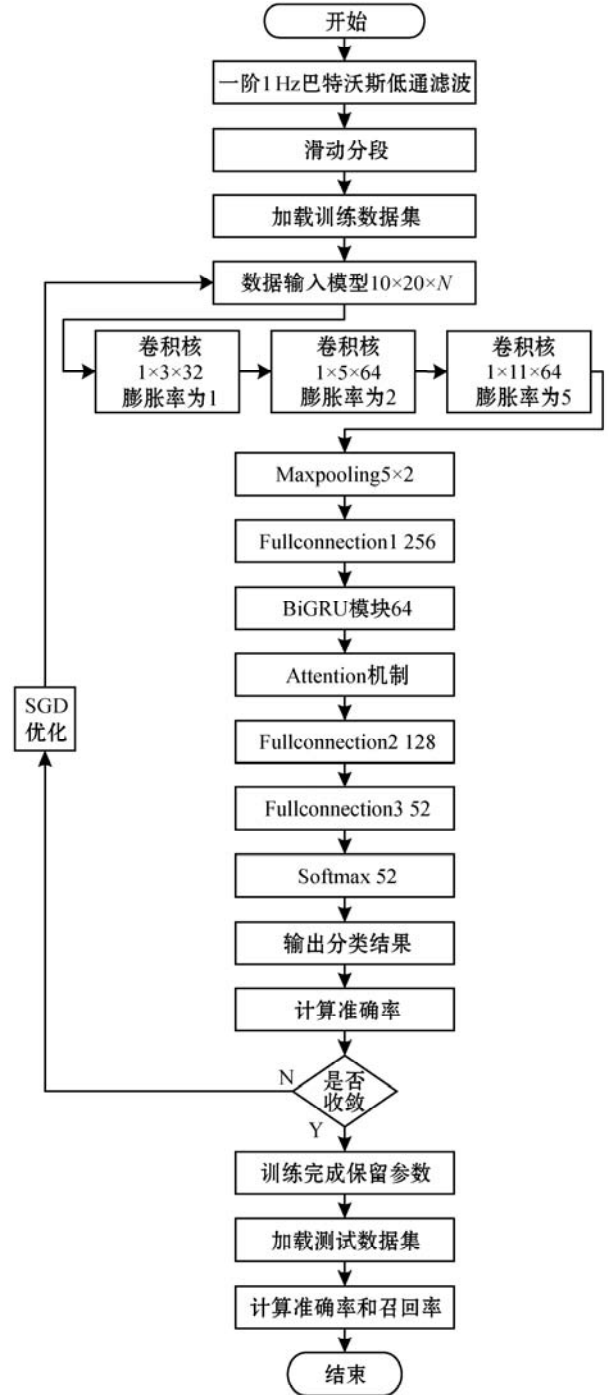


图 11 本文机器学习流程

卷积模块的输出经过 5 × 2 的 Maxpooling，可以防止过拟合，再经过全连接层对特征进行整理转换，送入包含 64 个 BiGRU 单元进行时序特征提取，再送入 Attention 机制模块赋予特征权重，然后送入全连接层整理特征，最后送入 Softmax 层分类并输出结果，共 52 个动作。因此，第三个全连接层有 52 个神经元，最终输出 52 个结果。最后计算并输出分类准确率和召回率。在第一和第二个全连接层以及 BiGRU 模块之后

应用概率为 50% 的 dropout。选择随机梯度下降算法 (SGD) 作为优化算法。初始学习率设置为 0.1, 权重衰减系数设置为 0.01, 动量参数设置为 0.9。

### 3.2 实验结果分析

将本文方法与其他四种方法进行比较, 包括基于卷积神经网络手势识别方法 CNN1<sup>[11]</sup>、基于深度学习和特征选取的动作识别方法 CNN2<sup>[7]</sup>、基于新肌电信号和卷积神经网络的手势识别方法 MinCNN<sup>[12]</sup> 以及基于长短时记忆和卷积神经网络手势识别方法 CNN + LSTM<sup>[4]</sup>。这几种方法都应用到不同形式的卷积神经网络及相同数据集, 具有比较好的对比性。参与实验对比的方法如表 2 所示。

表 2 模型方法对比

模型	方法
CNN1	卷积神经网络
CNN2	卷积神经网络, 将多肌电特征图作为输入
MinCNN	卷积神经网络, 将特征进行不同尺寸的分解作为输入
CNN + LSTM	CNN + LSTM + Attention 机制, 将肌电图 + 小波包特征图像作为输入
本文方法	HDC + BiGRU + Attention 机制, 将 10 × 20 肌电图作为输入

通过实验得到基于 HDC-BiGRU-Attention 模型方法的实验数据的训练集和测试集的准确率曲线, 如图 12 所示。上面一条曲线是训练集的准确率曲线, 下面一条曲线表示测试集准确率曲线。




图 12 训练集和测试集准确率曲线图

经过不断的实验优化, 最终实现了较为理想的准确率曲线, 可以看出, 在初始阶段训练集曲线较陡, 上升速度很快, 第 5 次之后曲线变缓, 上升速度变慢, 中间部分出现一定幅度的波动, 后面逐渐趋于稳定并最终并稳定在 97% 左右, 并实现最高 97.21% 的准确率。测试集在初始阶段上升较训练集慢, 后面稳步上升, 在第 5 ~ 10 次之间出现比较明显的波动, 且上升速度逐渐变慢, 曲线变缓, 后面波动逐渐减小, 最终稳定在

92% 以上, 准确率最大可以达到 92.72%。通过训练集与测试集准确率曲线的对比可以看出该方法对 sEMG 信号手势识别有较好的效果。可以看到模型在训练阶段准确率最高达到了 97.21%, 在测试集实验中准确率出现了较大幅度的降低, 降低了 5.51%。

将本文方法和其他方法对训练和测试的准确率以柱状图的形式进行对比, 图 13 所示为训练集准确率, 图 14 所示为测试集准确率。可以看出在测试集上本文方法取得了最高的准确率。




图 13 训练集准确率对比图




图 14 测试集准确率对比图

从图 13 可以看出这几种方法在训练集上都取得了很高的准确率, 其中 CNN1 和 CNN2 分别取得 92.07% 和 97.86% 的准确率, MinCNN 和 CNN + LSTM 分别取得 95% 和 84.12% 的准确率, CNN2 模型以多肌电信号特征集为输入在训练集的实验中取得了最高的准确率, 本文方法取得了 97.21% 的准确率, 在准确率上与 CNN2 模型相当。

从图 14 可以看出, 与训练集相比, 这几种方法在测试集上准确率都出现了较大幅度的下降。其中 MinCNN 下降幅度最大达到 19.49 百分点, 最终准确率达到 75.51%, CNN1 下降了 14.74 百分点, 最终准确率为 77.33%, CNN + LSTM 也出现了 9 百分点的下降, 准确率达到 75.12%, CNN2 也出现了 7.69 百分点的下降, 准确率达到 90.17%, 本文出现了 4.49 百分点的下降, 最终准确率达到 92.72%。本文方法实现了最高的准确率, 证明了本文方法在肌电信号的手势识别应用上效果优于其他四种方法。

召回率 (Recall rate) 也是评估识别效果的指标之一, 计算方法如式 (14) 所示。

$$R = \frac{\sum_{i=1}^n \text{正确分类为 } i \text{ 类的数目}}{i \text{ 类的实际数目}} \quad (14)$$

式中:  $i$  表示类别;  $n$  表示类别总数。

经过计算,本文方法的召回率为 89.23%。其中,有两个抓取动作非常相似,分类效果较低,总体分类效果良好。

本文方法在自采数据集上也有良好的识别效果。自采数据集采用 biosignalsplux 生物信号采集设备进行采集,数据实时接收和波形查看软件为 OpenSignals。采集现场如图 15 所示。




图 15 肌电信号采集设备

采集距离手部最近且肌肉较为密集的小臂信号,共 25 387×8 个数据,包括握拳、五指张开、竖大拇指、比“八”字和 OK 手势五种动作。实验准确率如图 16 所示。




图 16 自采数据准确率

由于握拳和五指张开这两个动作与其他动作相似度最低,因此实现了最高的准确率,其他三组动作也取得了较高的识别准确率。五种手势平均准确率达 97.85%,召回率为 95.71%,验证了本文方法的有效性。

## 4 结 语

混合空洞卷积神经网络不仅可以扩大感受野,还可以减少因网络过深产生大量的参数,重要的是可以减少过拟合。双向 GRU 网络可以很好地提取时序特征,模型能够提取到更多数据特征对提高准确率有重要作用。Attention 机制为特征赋予不同的权重,也是提高准确率的重要手段。由于数据的稀疏性,在模型中并没有在每个卷积层后都添加池化层,而是在卷积模块之后添加,以保留更多数据特征。相比于传统的 SVM 等分类方法,卷积神经网络不需要人工提取特征,减少了工作量,提高了效率。最终本文方法在公共数据集 NinaproDB1 上测试集准确率最高达到 92.72%,比其他方法有着显著的提升,在自采集的数据集上也取得了 97.85% 的准确率。

## 参 考 文 献

- [1] Du Y, Jin W G, Wei W T, et al. Surface EMG-based interaction gesture recognition enhanced by deep domain adaptation[J]. *Sensors*,2017,17(3):458.
- [2] Cene V H, Tosin M, Machado J, et al. Open database for accurate upper-limb intent detection using electromyography and reliable extreme learning machines[J]. *Sensors*,2019,19(8):1864.
- [3] Atzori M, Gijsberts A, Heynen S, et al. Building the Nina-pro database: A resource for the biorobotics community [C]//4th IEEE RAS/EMBS International Conference on Biomedical Robotics and Biomechanics,2012:1258 - 1265.
- [4] 陈思佳,罗志增.基于长短时记忆和卷积神经网络的手势肌电识别研究[J]. *仪器仪表学报*,2021,42(2):162 - 170.
- [5] Geng W D, Du Y, Jin W G, et al. Gesture recognition by instantaneous surface EMG images[J]. *Scientific Reprints*,2016,6:36571.
- [6] Fang Y C, Li Y F, Tu X K, et al. Face completion with hybrid dilated convolution[J]. *Elsevier*,2020,80:115664.
- [7] 余明超.基于深度学习和肌电特征选取的手部动作识别研究[D].武汉:武汉科技大学,2020.
- [8] Cote-Allard U, Fall C L, Campeau-Lecours A, et al. Transfer learning for sEMG hand gesture recognition using convolutional neural networks[C]//IEEE International Conference on Systems, Man, and Cybernetics,2017:1663 - 1668.
- [9] Jafarzadeh M, Hussey D C, Tadesse Y. Deep learning approach to control of prosthetic hands with electromyography signals[C]//IEEE International Symposium on Measurement and Control in Robotics,2019.
- [10] Atzori M, Cognolato M, Muller H. Deep learning with convolutional neural networks applied to electromyography data: A resource for the classification of movements for prosthetic hands[J]. *Frontiers in Neurorobotics*,2016,10(9):27656140.
- [11] 王逸桐,许成哲.基于 CNN 模型的 sEMG 信号手势动作识别算法[J]. *电子质量*,2021(1):6 - 9.
- [12] Gao R, Guo J, He Y P, et al. Gesture recognition algorithm based on new EMG representation and convolutional neural network [C]//IEEE Chinese Automation Congress, 2020: 3697 - 3701.
- [13] Yusuke Y, Yosuke O, Ryu K. EMG-based posture classification using a convolutional neural network for a myoelectric hand[J]. *Biomedical Signal Processing and Control*,2020,55:101574.
- [14] Simao M, Neto P, Gibaru O. EMG-based online classification of gestures with recurrent neural networks[J]. *Elsevier*,2019,128:45 - 51.
- [15] 张全龙,王怀彬.基于膨胀卷积和门控循环单元组合的人

- 侵检测模型[J]. 计算机应用,2021,41(5):1372-1377.
- [16] 张松,李江涛,别东洋,等. 一种基于单通道 sEMG 分解与 LSTM 神经网络相结合的手势识别方法[J]. 仪器仪表学报,2021,42(4):228-235.
- [17] 张兰霞,胡文心. 基于双向 GRU 神经网络和双层注意力机制的中文文本任务关系抽取研究[J]. 计算机应用与软件,2018,35(11):130-135,189.
- [18] 燕婷,王于超,金中一. 基于 CNN 与 GRU 降噪自编码的心电信号分类方法[J]. 软件导刊,2020,19(4):75-78.
- [19] 丁娜娜,张龙波,吴志勇. 基于 CNN 和 BiGRU-Attention 模型的心律异常判别研究[J]. 网络安全技术与应用,2021(2):12-18.
- [20] Luong M T, Pham H, Manning C D. Effective approaches to attention-based neural machine translation[C]//Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing. ACL,2015.
- [21] Kyunghyun C, Yoshua B. Neural machine translation by jointly learning to align and translate[EB]. arXiv:1508.04025,2016.
- [22] Yin W P, Schutze H, Xiang B, et al. ABCNN: Attention-based convolutional neural network for modeling sentences pairs[EB]. arXiv:1512.05193,2018.
- [23] 马利,刘新宇,李皓宇,等. 应用空洞卷积的神经网络轻量化方法[J]. 计算机工程与应用,2022,58(5):85-93.
- [24] Khushaba R, Kodagoda S, Takruri M, et al. Toward improved control of prosthetic fingers using surface electromyogram(EMG) signals[J]. Expert Systems with Applications, 2012,39:10731-10738.
- [25] Cao F L, Guo W H. Deep hybrid dilated residual networks for hyperspectral image classification[J]. Neurocomputing, 2020,384:170-181.
- [26] Li C M, Qiu Z L, Cao X Y, et al. Hybrid dilated convolution with multi-scale residual fusion network for hyperspectral image classification[J]. Micromachines,2021,12(5):545.
- [27] 程广涛,巩家昌,赵洪伟. 基于膨胀卷积和稠密连接的烟雾识别办法[J]. 计算机工程,2020,46(4):253-259.
- [28] Yu F, Koltun V. Multi-scale context aggregation by dilated convolutions[EB]. arXiv:1511.07122,2016.
- [29] Al-Hadeethi H, Abdulla S, Diykh M, et al. Adaptive boost LS-SVM classification approach for time-series signal classification in epileptic seizure diagnosis applications[J]. Expert Systems with Applications,2020,161:113676.
- [30] 杭成成. 基于 sEMG 信号的下肢运动意图识别研究[D]. 武汉:武汉理工大学,2019.
- [9] Hamidi-Sepehr F, Kwak Y, Chatterjee D. 5G NR PDCCH: Design and performance[C]//IEEE 5G World Forum,2018:250-255.
- [10] Kim T Y, Kim Y S. Dynamic PDCCH adaptation based on DMRS detection for UE power saving in 5G new radio[C]//90th Vehicular Technology Conference,2019:1-2.
- [11] Braun V, Schober K, Tirola E. 5G NR physical downlink control channel: Design, performance and enhancements[C]//IEEE Wireless Communications and Networking Conference,2019:1-6.
- [12] 李琳潇. LTE-A 空口监测分析仪小区搜索的研究与实现[D]. 重庆:重庆邮电大学,2019.
- [13] Jalali A, Ding Z. Joint detection and decoding of polar coded 5G control channels[J]. IEEE Transactions on Wireless Communications,2020,19(3):2066-2078.

~~~~~

(上接第 219 页)

- [6] Rossi L, Musolesi M. It's the way you check-in: Identifying users in location-based social networks[C]//2nd ACM Conference on Online Social Networks,2014:215-226.
- [7] Riederer C, Kim Y, Chaintreau A, et al. Linking users across domains with location data: Theory and validation[C]//25th International Conference on World Wide Web, 2016:707-719.
- [8] Mikolov T, Sutskever I, Chen K, et al. Distributed representations of words and phrases and their compositionality[EB]. arXiv:1310.4546,2013.
- [9] Zhou F, Gao Q, Trajcevski G, et al. Trajectory-User linking via variational autoencoder[C]//27th International Joint Conference on Artificial Intelligence,2018:3212-3218.
- [10] Luo X, Li S, Peng Y. CNNTOP: A CNN-based trajectory owner prediction method[EB]. arXiv:2001.01185,2020.
- [11] Yang Z, Yang D, Dyer C, et al. Hierarchical attention networks for document classification[C]//2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2016:1480-1489.
- [12] Miao C, Wang J, Yu H, et al. Trajectory-User linking with attentive recurrent network[C]//19th International Conference on Autonomous Agents and MultiAgent Systems,2020:878-886.
- [13] Feng J, Zhang M, Wang H, et al. Dplink: User identity linkage via deep neural network from heterogeneous mobility data[C]//The World Wide Web Conference,2019:459-469.
- [14] Ma C Y T, Yau D K Y, Yip N K, et al. Privacy vulnerability of published anonymous mobility traces[C]//16th Annual International Conference on Mobile Computing and Networking,2010:185-196.

~~~~~

(上接第 192 页)

- [8] 张德民,曾艳辉,张洋. 5G 中基于功率测量的 PDCCH 自适应盲检测算法[J]. 计算机应用与软件,2020,37(3):117-122.