

采用变分模态分解与领域自适应的 表面肌电信号手势识别

姜海燕^{1,2}, 许先静^{1,2}, 钟凌珺^{1,2}, 李竹韵^{1,2}

(1. 福州大学电气工程与自动化学院, 350108, 福州;

2. 福建省医疗器械和医药技术重点实验室, 350108, 福州)

摘要: 针对传统机器学习在表面肌电信号手势识别领域的适应性和准确性不足,以及新用户因个体生理和行为差异在已有模型上表现不佳的问题,提出一种利用卷积神经网络模型并有效克服肌电数据分布差异的算法,用于提升手势识别的性能。首先对肌电信号进行变分模态分解,构建易于识别的表面肌电图像,并提出了一种卷积神经网络模型进行手势识别,提升用户相关的肌电信号手势识别准确率;同时利用迁移学习中的领域自适应和模型微调技术,提升用户无关的肌电信号手势识别准确率,并将所提算法在 NinaPro DB1 肌电数据集中进行了 3 分类、4 分类、5 分类和 12 分类共 4 组评估验证。结果表明:在 4 组评估验证中,用户相关的肌电信号手势识别平均准确率分别达到了 99.28%、99.30%、98.39%和 93.40%,用户无关的肌电信号手势识别平均准确率分别达到了 94.05%、92.60%、88.38%和 70.03%,表明本文提出的算法在表面肌电信号手势识别中具有良好的效果,为实现人机交互中的普适性的肌电设备开发提供了一种可行的方案。

关键词: 领域自适应;卷积神经网络;手势识别;变分模态分解;表面肌电信号

中图分类号: TH772 **文献标志码:** A

DOI: 10.7652/xjtuxb202405008 **文章编号:** 0253-987X(2024)05-0075-13

Gesture Recognition of Surface Electromyography Based on Variational Mode Decomposition and Domain Adaptation

JIANG Haiyan^{1,2}, XU Xianjing^{1,2}, ZHONG Lingjun^{1,2}, LI Zhuyun^{1,2}

(1. College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350108, China;

2. Fujian Provincial Key Laboratory of Medical Devices and Medical Technology, Fuzhou 350108, China)

Abstract: In view of the lack of adaptability and accuracy of traditional machine learning in the field of gesture recognition of surface electromyography (sEMG), as well as the poor performance of new users on existing models due to individual physiological and behavioral differences, an algorithm using convolutional neural network model to effectively overcome the difference in the distribution of EMG data is proposed to improve the performance of gesture recognition. A novel approach combining variational mode decomposition (VMD) of sEMG signal and convolutional neural network is proposed to enhance the performance of gesture recognition in the subject. In addition, domain adaptation and model fine-tuning techniques of transfer learning are used to increase the accuracy

of gesture recognition of intra-subject sEMG. The proposed algorithm is evaluated and validated on four evaluation groups of the benchmark dataset DB1 with 3, 4, 5 and 12 classifications. In the four sets of evaluation, the average accuracies of inter-subject are 99.28%, 99.30%, 98.39% and 93.40% respectively, and the average accuracies of intra-subject are 94.05%, 92.60%, 88.38% and 70.03% respectively. Through the experimental results and own data validation, it is proved that the proposed algorithm has a good effect on the gesture recognition of sEMG signals, which is more conducive to the realization of human-computer interaction and provides a feasible solution for the development of universal sEMG equipment.

Keywords: domain adaptation; convolutional neural network; gesture recognition; variational mode decomposition; surface electromyography

肌肉计算机交互(MCI)被广泛应用于假肢控制^[1]、机器人控制^[2]、手语识别^[3]和人机交互^[4]等领域,而手势识别是MCI的核心技术。手势识别主要包括识别手部姿态、物体抓取和手部运动等^[5],被运用在众多领域,如计算机游戏、外骨骼机器人^[6]、医疗康复机器人^[7-8]等。目前,手势识别主要通过数据手套、图像识别、肌电信号等方式实现^[9]。数据手套在手势识别中拥有较高的准确率,但便捷性差,使用不便;基于图像识别的手势识别技术易受光照、遮挡、背景等环境因素的影响;表面肌电信号蕴含丰富的运动信息且具有易获取和无创等优势,能够根据人的自主意识更方便自如地实现人机交互,在人机交互中有着很大的优势。

基于表面肌电信号(sEMG)的手势识别研究目前主要包括机器学习算法和深度学习算法。机器学习算法通过采集表面肌电信号并进行预处理后,提取表面肌电信号特征,并构建合适的分类器如支持向量机、朴素贝叶斯分类器、随机森林和神经网络等^[10]来识别肢体动作,其结果主要受限于特征提取和分类器选择。例如,Freitas等^[11]利用支持向量机(SVM)进行13个手势的识别,最终手势识别准确率达到88%;Fu等^[12]提出了一种基于格莱氏角求和场线性判别分析的特征增强和改进的支持向量机,并对8个手势进行分类,识别准确率达到97.54%;Waris等^[13]提取肌电信号特征后通过人工神经网络对手势进行分类,结果表明人工神经网络比传统的K最邻近算法(KNN)和SVM算法性能更加优越。随着深度学习被广泛应用于生物电信号识别^[14],相较于机器学习,深度学习在基于sEMG手势识别中,肌电识别准确率、普适性和泛化能力上有了较大的提升^[15-16]。Atzori等^[17]利用一个简单的4层卷积神经网络(CNN),在NinaPro DB1肌电数据集^[18]上对53种手势动作进行识别,

准确率达到66.59%±6.40%,相比于传统的KNN和SVM算法,其准确率提高了2%~5%;陈思佳等^[19]提出基于长短时记忆和卷积神经网络的手势肌电识别方法,在NinaPro DB1肌电数据集上实现了75.12%的准确率,优于机器学习算法;Qureshi等^[20]利用一种链接卷积神经网络对9个手势进行分类,在NinaPro DB1肌电数据集上达到了91.27%的准确率;Li等^[21]提出了一种多视图融合神经网络对12个手势进行分类,在NinaPro DB1肌电数据集上达到了89.58%的准确率。以上充分表明深度学习在表面肌电信号识别中具有优势。

尽管个体的骨骼和肌肉组成基本一致,但其生理特征存在一定的差异^[22],同时不同个体在执行相同动作时肌肉的收缩方式和收缩力大小不同,且是否使用惯用手等也存在一定的差异,这些差异导致将训练好的模型应用于新用户的手势识别时表现不佳。为了解决由个体差异而导致模型识别率下降的问题,学者们提出了以下3种方案。①融合不同个体的多模数据,即扩充有监督学习算法中训练数据的数量及类型。Guo等^[23]融合了多位受试者的数据,用于训练一个通用网络模型,其优势在于新用户可直接使用,不用重新采集数据和训练模型。Xu等^[24]提出了一种基于注意体系结构的卷积神经网络(SE-CNN)的手势识别方法,将多个用户的数据进行融合作为训练集,在用户无关手势识别中的手势识别准确率达到65.74%。②提取肌电分解与协同特征,即通过肌电分解、多特征融合等方式构建统一化的特征空间。Xiong等^[25]对肌电信号进行逆向分解,把不同受试者的肌电信号分解到运动单元动作电位(MUAP)的信号空间。通过MUAP的无监督聚类,找到用于个体无关的表征方式,降低了受试者之间的差别。Ison等^[26]提出了基于多分辨率肌肉协同特征提取方法,以构建个体适应的鲁棒

特征。郑楠等^[27]利用肌肉协同原理,通过坐标空间转换改造数据解决用户无关的问题。③通过少量数据更新通用模型。Khushaba 等^[28]利用典型相关分析(CCA)方法,将不同受试者的肌电特征映射到一个低维的同一空间训练预训练模型,并对新用户的少量肌电信号与预训练模型的专家特征做典型相关分析,将测试集数据更新至预训练模型高相关性空间,模型的适用性和泛化能力得到了提升。Kanoga 等^[29]通过迁移学习方法提出了一个基于多重距离度量的主题转移框架,最小化用户之间的数据分布差异,以此解决用户无关的手势识别问题。上述方法中,融合不同个体的多模数据,不仅扩增耗时间长,增加了个体用户模型的学习成本,而且提取肌电分解与协同特征在新的场景中需重新探寻鲁棒特征;另外,前两种方法均为有监督学习,在实际应用中适用于有标记数据。利用少量数据更新模型需利用相关性映射对用户数据进行改造,或者利用迁移学习等方法对模型参数进行更新。其中,利用少量数据更新模型的方法,可以结合无监督学习,且所需的新样本数少,更新代价小,更有利于可穿戴式设备的开发。

针对上述问题,本文对肌电信号预处理后进行肌电信号分解,并构建易于识别的表面肌电图像,同时提出了一种卷积神经网络模型进行表面肌电信号手势识别,提升用户相关的手势识别准确率;利用迁移学习中的领域自适应方法,用少量数据更新 CNN 模型,提升用户无关的手势识别准确率;通过模型微调进一步提升用户无关的手势识别准确率。

1 实验数据与方法

1.1 实验数据

NinaPro 肌电数据集是一个多模态数据集,记录了表面肌电信号、手部运动学、眼球跟踪和神经认知等数据,目前共有 10 个子数据集。本文采用其中的 DB1 数据集作为模型的训练和测试数据。DB1 数据集的采集对象为 27 位受试者(其中 20 名男性,7 名女性,平均年龄 28 岁),运动学数据采集设备为融合 22 个传感器的 Cyberglove II dataglove,表面肌电信号设备采用具有十通道(差分双电极)的 OttoBock MyoBock。采集过程中受试者保持特定的坐姿面向屏幕,根据屏幕提示重复特定的动作。每类动作重复 10 次,每个动作保持 5 s、休息 3 s,实验过程中共采集 53 个不同的手部动作(标签号为 0~52),手势的标签及动作分类如表 1 所示。

表 1 DB1 数据集标签及手势类别分组
Table 1 DB1 data set label and gesture category grouping

标签	手势动作分类
0	静息
1~12	手指动作
13~29	手或手腕部分的动作
30~52	抓握动作

考虑到应用场景中常用的手势动作,本文选取 3 个抓握动作、5 个手或手腕动作和 12 个手指动作,同时为了与其他文献研究成果进行对比,将手势分为 4 组进行实验对比,具体分组如图 1 所示。



图 1 手势选取及实验分组

Fig. 1 Gesture selection and experimental grouping

1.2 卷积神经网络模型

卷积神经网络是一种多层的有监督学习神经网络,具有局部感知、权值共享等特点,能有效减少神经网络结构中的参数,减少深层网络占用的内存量。本文的网络模型结构如图 2 所示。由于表面肌电图像的尺寸较小,因此采用 4 个卷积层进行特征提取;为了防止信息的丢失,模型中省去池化层。在模型中通过采用 dropout 层、批量归一化和正则化等方法以防止网络过拟合。

本文的卷积神经网络模型中共用 4 个卷积层进行特征提取,随后利用展平层将提取的特征展平成一维向量,再通过 2 个全连接层和 softmax 层对手势进行分类。图 2 中,Conv64 表示卷积层的卷积核为 64, @3×3 表示卷积核大小为 3×3,BN 表示引入批量归

一化,卷积层中的激活层函数均采用 Relu 函数;其后是展平层和 2 个全连接层,神经元数分别为 128、64,均应用 Relu 激活函数和批量归一化,为了防止模型

过拟合,全连接层应用了概率为 50% 的 dropout 层;最后的输出层采用归一化指数函数得到手势识别结果,并采用 L_2 正则化方法,设定正则化参数为 0.001。




图 2 卷积神经网络模型
Fig. 2 Convolutional neural network model

实验平台 CPU 采用 Inter i7 8700,GPU 采用惠普 GTX 1080,软件采用 TensorFlow 2.7。采用交叉熵损失函数,计算公式如下

$$L = - \frac{1}{n} \sum_{i=1}^n (y_i \lg y_i^*) \tag{1}$$

式中: y_i^* 为当前训练样本对应的真实标签值; y_i 为网络的输出值; n 为样本数。

基于上述模型对不同的卷积层和卷积核大小进行手势识别实验。训练过程中的超级参数表如表 2 所示,实验结果如表 3 所示。

表 2 卷积神经网络的超级参数表
Table 2 Hyperparameter table of convolutional neural networks

参数	数值
初始学习率	0.001
负责性衰减率 β_1	0.9
二次性衰减率 β_2	0.99
数值稳定性参数 ϵ	10^7
批量大小	32
迭代次数	100

表 3 不同卷积层和核条件下的实验结果
Table 3 Experimental results of different convolution layers and convolution kernel conditions

卷积层数	卷积核大小	手势识别准确率/%
4	1×5	92.73
4	5×1	91.51
4	5×5	93.63
4	1×3	91.51
4	3×1	92.34
1	3×3	92.47
2	3×3	92.86
3	3×3	93.44
4	3×3	94.21
5	3×3	94.24
6	3×3	94.26

从表 3 可以看出,当卷积层数增多时,手势识别准确率上升;当卷积层数超过 5 时,手势识别准确率上升减缓,考虑到随着卷积层数增多,模型的参数量将增加,不利于可穿戴设备的实时性,同时当卷积核为 3×3 时,手势识别准确率最高,因此本文模型取卷积层数为 4,卷积核大小为 3×3 。

1.3 数据预处理

表面肌电信号是一种微弱信号,其信号幅值不超过 3 mV,容易受接触不良、电极移位/脱离、被测人员皮肤状态差异等多种因素的影响,因此首先要对表面肌电信号进行滤波等预处理。NinaPro DB1 数据集在采集时进行过全波整流等数据处理。所以,采集的数据中只包含高频噪声。本文的滤波方案采用文献[30]中的巴特沃斯滤波器对信号进行滤波降噪,图 3 所示为滤波前后的信号对比。为了解决采集数据时个体对动作提示的反应存在差异,导致原标签和实际动作不一定相互对应的问题,通过广义似然比算法进行了标签的重映射[30],本文采用重映射后的数据标签。




图 3 滤波前后的信号对比

Fig. 3 Signal comparison before and after filtering

1.4 肌电信号分解及肌电图像构建

变分模态分解(VMD)是一种信号分解估计的信号处理方法,克服了经验模态分解方法存在的端点效应和模态分量混叠问题,有着坚实的数学理论依据^[31],可以降低表面肌电信号的复杂度和非线性。VMD可以根据给定的模态分解个数,通过迭代寻优的过程确定各个分量的中心频率和带宽,实现信号的频域划分和各个模态分量(IMF)的有效分离。

VMD的核心是构建并求解变分问题^[32]。构建问题:设将原信号 $f(t)$ 分解为 k 个具有不同中心频率的有限带宽的模态分量,同时使得各个模态分量的估计带宽之和最小,约束条件为各模态分量叠加后与原始信号相等,则相应的约束变分表达式为

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t [(\delta(t) + j/\pi t) * u_k(t)] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (2)$$

s. t. $\sum_{k=1}^k u_k = f(t)$

式中: u_k 、 ω_k 为模态分解后对应的第 k 个模态分量及其中心频率; $*$ 为卷积运算符; $\delta(t)$ 为狄拉克函数; j 代表虚部单位; t 为采样时间。

对式(2)进行求解,在保持约束条件不变的条件将约束变分问题转变为非约束变分问题,引入拉格朗日乘法算子 λ ,得到增广拉格朗日表达式

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial_t [(\delta(t) + j/\pi t) * u_k(t)] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \lambda(t) \cdot (f(t) - \sum_k u_k(t)) \quad (3)$$

式中: α 为二次惩罚因子,目的是减少高斯噪声的干扰。采用交替方向乘子(ADMM)迭代算法不断迭代寻优各模态分量及其中心频率,最终得到各模态分量对应的最佳中心频率,交替寻优迭代后的 u_k 、 ω_k 、 λ 的表达式如下

$$\begin{cases} \hat{u}_k^{n+1}(\omega) \leftarrow \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \hat{\lambda}(\omega)/2}{1 + 2\alpha(\omega - \omega_k)^2} \\ \omega_k^{n+1} \leftarrow \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \\ \hat{\lambda}^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + \gamma(\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega)) \end{cases} \quad (4)$$

式中: $\leftarrow$ 表示迭代更新方向; γ 为噪声容忍度; n 为迭代的次数; $\hat{u}_k^{n+1}(\omega)$ 、 $\hat{u}_i(\omega)$ 、 $\hat{f}(\omega)$ 、 $\hat{\lambda}(\omega)$ 分别对应

$u_k^{n+1}(t)$ 、 $u_i(t)$ 、 $f(t)$ 和 $\lambda(t)$ 的傅里叶变换。其中迭代过程的约束条件为

$$\frac{\sum_{k=1}^K \left\| \hat{u}_k^{n+1} - \hat{u}_k^n \right\|_2^2}{\left\| \hat{u}_k^n \right\|_2^2} < \epsilon \quad (5)$$

式中: ϵ 为给定的精度。

根据以上分析,VMD的主要迭代过程为:

步骤1 初始化参数 $\hat{u}_k$ 、 ω_k 、 $\hat{\lambda}$,设置最大迭代次数 $n_{\max}$;

步骤2 使用式(4)更新 $\hat{u}_k$ 、 ω_k 、 $\hat{\lambda}$;

步骤3 判断是否满足式(5)或者 $n \geq n_{\max}$,若不满足,则重复步骤2继续迭代优化;若满足,则输出最后的参数 $\hat{u}_k$ 、 ω_k 。

拉格朗日算子 λ 主要用于增强约束条件,而二次惩罚因子用于提升收敛性并且二次惩罚因子和加性高斯噪声之间具有很强的相关性。本文目的是使得分解后的IMF不含噪声,因此保留二次惩罚因子,放弃拉格朗日算子是最好的选择。为了使拉格朗日算子为0,最简单的方式就是将噪声容忍度置为0^[32]。本文VMD分解相关参数的设置为:精度 $\epsilon = 0.000\ 001$,惩罚因子 $\alpha = 2\ 000$,噪声容忍度 $\gamma = 0$ 。对于模态分解个数 k ,若设置过小,会导致信号分解不彻底,若设置过大,不仅会大大增加VMD分解计算时长,还会使分解后的IMF中心频率相距过近,造成模态混叠。本文利用皮尔逊相关系数分析VMD分解后的手势样本数据,同类别手势中若两个样本的相似程度越高,越有利于模型将其归为一类。皮尔逊相关系数计算公式如下

$$p_{I,J} = \frac{\text{Cov}(I,J)}{\sigma_I \sigma_J} \quad (6)$$

式中: $\text{Cov}(I,J)$ 代表样本 I 、 J 之间的协方差; σ_I 、 σ_J 分别表示两个样本的标准差。

图4为当 k 选取不同数值时受试者的所有同类别手势样本之间皮尔逊相关系数的平均值。由图4可知,当 k 值越大时,手势样本之间的相关性越强,但会导致VMD分解的计算时长增加;当 k 大于5时,相关系数增长的斜率变缓,综合考虑将 k 设置为5。

图5为某位受试者的每个手势所有样本之间的平均皮尔逊相关系数。由图5可知,滤波后的信号比滤波前的信号各手势样本之间的相关性强,而利用VMD分解后的IMF1分量的各手势样本的相关性更强,说明VMD方法处理后的信号更有利于手势分类。




图 4 不同 k 值下手势样本的平均皮尔逊相关系数

Fig. 4 Average Pearson correlation coefficients of gesture samples with different k values




图 5 某受试者各手势的平均皮尔逊相关系数
Fig. 5 The average Pearson correlation coefficient of gestures for a subject

基于深度学习的表面肌电信号手势识别算法，通过滑动窗口将多通道表面肌电信号转换成表面肌电图像。随后，表面肌电图像作为深度学习模型的输入，实现肌电特征的自动提取。图 6 所示为一维表面肌电信号的图像构造，将预处理后的表面肌电




图 6 表面肌电图像的构建
Fig. 6 Construction of sEMG images

信号通过滑动窗口分割为多个表面肌电图像。数据点采样周期为 10 ms。滑动窗口的宽度设置为 20 (200 ms)，步长设置为 17 (170 ms)，通过该滑动窗口分割 10 个通道得到 10×20 的一维表面肌电图像。处理后，每位受试者的肌电图像样本数可以达到 10 000 个左右，达到深度学习算法对样本数据量的要求，并且由于表面肌电信号的产生比人体肌肉运动早 30~150 ms，因此 20 (200 ms) 的滑动窗口可以满足人机交互技术的实时性要求。

在进行数据预处理后，为了构建更易识别的表面肌电信号图像，对表面肌电信号的每个通道分别进行变分模态分解。将得到的各变分模态分量及表面肌电信号分别构建表面肌电图像并进行手势分类，构建的 sEMG 图像作为上述模型的输入，结果如图 7 所示。由图 7 可见，原表面肌电信号 (RAW) 构成的肌电图像识别准确率为 86.88%，而变分模态分解后的 IMF1 和 IMF2 分量所构建的表面肌电图像的准确率分别提高了 6.94% 和 2.76%，利用前 3 个 IMF 构成的三维肌电图像 (IMF1~3) 的识别准确率为 95.79%，比原表面肌电信号构成的肌电图像的识别率高出了 8.91%。因此，本文后续实验的肌电图像为变分模态分解后的前 3 个 IMF 所构成三维的肌电图像，构建的肌电图像尺寸为 $10 \times 20 \times 3$ 。




图 7 不同 IMF 分量和原表面肌电信号构成的表面肌电图像的手势识别准确率
Fig. 7 Gesture recognition accuracy of surface EMG images composed of different IMF components and original surface EMG signals

1.5 领域自适应

领域自适应算法属于基于模型迁移的迁移学习算法，分为无监督领域自适应和有监督领域自适应。无监督领域自适应的源域中有大量带标签的样本数据，而目标域的样本数据不带标签；有监督的领域自适应其目标域和源域均为带有标签的样本数据，且目标域的标签数据一般用于更新模型网络中神经网络的参数，称之为模型微调。领域自适应是机器学习的前沿研究方向之一，在人机交互和生物医学等

方面有着极大的应用前景^[33]。Du 等^[34]提出一种多流自适应批量归一化(AdaBN)领域自适应技术,在 NinaPro DB1 数据集的无关用户手势识别准确率达到 67.4%。Lai 等^[35]通过一种自监督的领域自适应技术,在样本较少的情况下仍能得到较好的手势识别结果。

不同个体肌电信号的核密度估计如图 8 所示,纵坐标表示样本数据分布的概率密度。可以看出,由于用户之间的数据分布差异,导致新用户 在已训练好的模型上表现不佳。本文将由个体差异导致的数据分布差异问题视为领域自适应问题,将用于模型训练的用户肌电数据视为源域,新用户的肌电数据视为目标域,通过领域自适应算法将已训练好的模型应用于新用户的手势识别中。领域自适应算法是应用已有的源域数据对网络模型进行训练,然后通过 对训练好的模型进行参数调整,使得源域和目标域中的数据分布尽可能地接近,使得训练好的网络模型可以在目标域中取得较好的泛化能力,提高目标域上的手势识别准确率,实现网络模型的复用。




图 8 不同个体肌电信号的核密度估计图

Fig. 8 Nuclear density estimation of EMG signals of different individuals

AdaBN 算法由 Li 等^[36]提出,是基于 BN 层的领域自适应算法,适用于无监督学习。该算法的核心是:在网络模型训练时,先利用源域 D 的样本数据进行训练,得到一个训练好的模型,此时的训练过程中,网络模型做正向传播和反向传播。随后选取目标域 T 的一小部分数据 $Q \in T$,在每一批次的训练过程中通过计算 Q 的方差和均值更新网络模型批量归一化(BN)层中均值和方差,此时的训练过程只需要做正向传播即可。由于 BN 层是对模型中各层的输出做批量归一化,而归一化需要用到训练数据的分布信息,因此通过上述的操作可以使源域和目标域的样本数据调整到一个新的分布空间,在这新的分布空间中,源域和目标域的样本数据具有相似的分布。本文将迁移学习中的 AdaBN 领域自适应算法与提出的卷积神经网络模型相结合应用于用

户无关的手势识别。

基于 AdaBN 的卷积神经网络模型流程图如图 9 所示。该算法先用旧用户(源域)数据训练本文提出的卷积神经网络模型,然后利用少量新用户(目标域)数据在已训练好的模型中进行前向传播,更新模型中 BN 层的参数。模型中 BN 层是个特殊的存在,它不参与反向传播,因此新用户的训练数据可以不需要标签。在训练中,对每一批次数据的相关参数进行调整,可以提高模型在新用户数据中的泛化能力。针对具有标签的预训练数据还可以利用模型微调,即用带标签的新用户数据对模型的全连接层进行参数更新,进一步提高网络的识别准确率。




图 9 基于领域自适应的肌电信号手势识别流程图

Fig. 9 The sEMG gesture recognition based on domain adaptation

2 结果与分析

2.1 用户相关验证

本文在 NinPro DB1 数据集进行实验验证,分为 4 组对比实验,分别为 3 个抓握动作、4 个手或手腕动作、5 个手或手腕动作和 12 个手指动作。参考以往的研究^[30],本文把每个手势 10 次重复中的第 2、5、7 次重复作为测试集,其余的 7 次重复作为训练集,用于训练模型和评估用户相关手势识别。同时采用常用的传统分类器 SVM、BP、KNN、随机森林^[27, 37-38]作为对照组进行对比实验,其中 BP 为 3 层隐藏层,神经元数分别为 512、128、64。上述算法的输入特征向量均采用平均绝对值、方差和均方根。测试集和训练集的划分同样遵循上述方式 1/3 的手势重复作为测试集,剩余的手势重复作为训练集。各基准算法与本文算法在基于用户相关的手势识别性能如图 10 所示,图中箱体中间的一条线代表中位数,箱体的上下边缘代表上四分位数和下四分位数,箱体包含了 50% 的数据,箱体外上下边缘线代表最大值、最小值。其平均分类准确率如表 4 所示。可以看出,本文采用的肌电信号分解和深度学习模型在 4 组实验中平均准确率均高于基准算法,在 4 组

实验中本文算法比最优的基准算法高出了 10.56%、5.33%、4.43% 和 21.05%，并且当手势类别为 12 时，基准算法的分类准确率下降较多，本文算法分类准确率下降较少，达到了 93.40%，表明本文算法提高了手势分类的准确性和鲁棒性。




图 10 基准算法与模型在基于用户相关手势识别结果箱体图



Fig.10 Box diagram of the results of the benchmark algorithm and proposed algorithm recognition based on user-related gestures

表 4 基准算法与本文算法在基于用户相关手势识别中的准确率

Table 4 Accuracy of benchmark algorithm and proposed algorithm in user-related gesture recognition

算法	手势识别准确率/%			
	1 组	2 组	3 组	4 组
SVM	87.76	91.09	90.94	69.98
BP	85.50	90.05	91.45	64.90
KNN	85.65	91.80	91.80	63.95
随机森林	88.72	93.97	93.96	72.35
本文	99.28	99.30	98.39	93.40

图 11(a)展示了某位受试者测试集的混淆矩阵,图 11(b)为该受试者手势识别的查全率及查准率。从图 11 可以看出,本文算法拥有较好的手势识别性能:对于测试集中的 10 个手势拥有较高的手势



(b)查全率及查准率

图 11 某位受试者测试集的手势识别性能

Fig.11 Gesture recognition performance of a test set for a subject

查全率和查准率,其中有部分标签为 10 的手势被识别为标签为 8 的手势,导致两个手势的查全率和查准率较低,其原因可能是两个手势的五指动作过于相似。从图 1 可以看出,两个手势动作的主要区别在于标签为 8 的手势腕部是向掌心翻转,而标签为 10 的手势腕部向掌背翻转。

将本文算法与现有的文献实验成果进行对比,结果见表 5。本文的算法在第 4 组实验中比文献 [27,30,34,39,21] 分别提高了 31.98%、7.4%、9.4%、8.7%、3.82%,文献[20]中选取了 9 个手势类别进行手势识别,本文手势类别数比其多了 3 个,并且准确率提高了 2.13%。与此同时,在另外 3 组的实验中本文算法也得到了较高的准确率,数据对比印证了本文算法在用户相关的肌电信号手势中具有一定的优越性。

表 5 本文算法与相关研究的手势识别准确率对比

Table 5 The gesture recognition accuracy of the method compared with that of relevant studies

来源	手势识别准确率/%			
	1 组	2 组	3 组	4 组
文献[27]	81.71	79.45	75.59	61.42
文献[30]	88.29			86.00
文献[34]				84
文献[39]				84.70
文献[21]				89.58
文献[20]				91.27
本文	99.28	99.30	98.39	93.40

注:表中加粗数据表示最优值。

2.2 用户无关验证

图 12 为用其中某位用户的第 4 组数据训练本文提出的模型,用另一位用户第 4 组数据的部分手势重复作为预训练数据,剩余手势重复作为测试集

的手势识别准确率。从图 12 可以看出,当预训练手势重复组数分别为 1、2、3、4、5 时,在测试集中的准确率分别为 35.10%、57.46%、65.44%、70.55%和 70.10%,测试集的准确率随预训练数据量的增多而升高。为了提高用户体验,即在采用较少的预训练数据的同时保证手势识别的准确率,本文采用用户的前 4 组手势重复作为模型的预训练集,后 6 组重复作为测试集。




图 12 不同预训练数量的手势识别准确率

Fig.12 Gesture recognition accuracy with different amount of pre-training

为了客观评价本文算法的性能,本文与目前主要用户无关的研究方法进行对比实验,并与文献[27]采取了相同的两重交叉验证方式评估算法性能。

第一重:每次采用其中 1 名用户数据训练模型,对其余用户(新用户)的数据对模型进行测试。重复 N 次($N = 27$),直到每个用户都被作为一次训练数据。

第二重:在第一重循环中,每次选取新用户的前 4 组手势重复作为预训练数据,剩余手势重复作为测试集。

同时,本文设置了不同的实验方案用于进一步验证本文算法的有效性:方案 1 为不用领域自适应,应用上述的两重交叉验证方式评估本文提出的模型;方案 2 和方案 1 的区别在于应用了 AdaBN 算法;方案 3 和方案 1 的区别在于应用了模型微调的方法;方案 4 和方案 2 的区别在于应用了模型微调的方法。

基于 AdaBN 的用户无关算法在方案 2 下的 4 组实验结果性能如图 13 所示。可以看出,4 组实验的无关平均分类准确率分别为 94.05%、92.06%、88.38%和 70.03%。表 6 为本文算法在第 4 组实验中 4 个方案的实验结果。可以看出,本文在应用领域自适应方法后,用户无关的手势识别准确率由 14.68%提高到了 70.03%。在仅应用模型微调时,

虽然用户无关的手势识别准确率提高到了 72.41%,但使用模型微调时其更新的参数量是应用领域自适应的百倍;方案 4 数据表明在应用领域自适应的前提下,通过模型微调可以进一步提升用户无关的手势识别准确率。表 6 中文献[40]同样采用领域自适应的方法且用作预训练和测试集的手势重复均为 5 个。相比文献[40],本文算法在方案 2 的情况下减少 1 组预训练的手势重复,但手势识别准确率提高了 14.06%,说明本文的算法更有利于用户无关的手势识别。




图 13 基于 AdaBN 的用户无关算法手势识别结果箱体图

Fig.13 Box diagram of gesture recognition result of user-independent algorithm based on AdaBN

表 6 本文算法与相关研究的手势识别准确率对比

Table 6 The gesture recognition accuracy of the method compared with that of relevant studies

来源	手势识别准确率/%			
	方案 1	方案 2	方案 3	方案 4
文献[40]	35.10	65.20		
本文	14.68	70.03	72.41	80.98

表 7 为本文基于方案 2 的用户无关手势识别结果与其他相关研究成果的对比。表中虽有部分文献采样频率与本文所用数据集不同,但采集协议相同,因此比较结果有意义。可以看出,本文在 4 组实验中比近年的方法的准确率分别提高了 12.93%、14.42%、14.3%和 4.83%。表 7 中文献[27,39]利用肌电分解和肌肉协同原理,通过特征变换来解决用户无关问题,其预训练过程为有监督学习,文献[30,29]分别使用了传统的机器学习方法和迁移学习方法,其准确率较低,文献[34,40]都应用了领域适应,通过少量数据更新通用模型,其预训练数据比本文多了 1 组手势重复。

表 7 基于用户无关的手势识别研究结果对比

Table 7 Comparison of research results based on user-independent gesture recognition

组号	数据来源	来源	手势识别准确率/%
1	DB1	文献[30]	48.52
	DB1	文献[27]	81.12
	DB1	本文	94.05
2	文献[39]	文献[39]	61.32
	DB1	文献[27]	78.18
	DB1	本文	92.60
3	文献[38]	文献[38]	68.23
	DB1	文献[27]	74.08
	DB1	本文	88.38
4	DB1	文献[30]	20.78
	文献[34]	文献[34]	35.10
	DB1	文献[40]	65.20
	DB1	文献[27]	60.11
	DB5	文献[29]	52.00
	DB1	本文	70.03

注：表中加粗数据表示最优值。

本文算法在只用领域自适应的情况下,手势识别的准确率高与其他研究方法,说明本文算法具有一定的优越性;由于本文提出的算法只将 BN 层参数设置为可训练,更新参数少,更适用于实际应用开发,且与其他的领域自适应的研究相比,本文中的预训练数据少,计算量小但准确率高。与文献[27]相比,本文训练过程为无监督学习,无需对预训练数据进行标记及提取肌电信号特征,且提高了准确率。

2.3 实测数据验证

为了进一步验证本文提出的算法在 MCI 相关领域实际应用中的可行性,进行了实测数据验证。肌电采集设备采用普升科技有限公司的 BioSemi AD-box 和 Active High-Density EMG electrode array 组成的肌电采集系统。实验共采集了 8 个受试者(其中 5 名男性、3 名女性,平均年龄 26 岁)的 12 个手势,分别为八字、OK、中间三指伸、两指伸、拇指伸、食指伸、中指伸、握拳、无名指伸、五指伸、小指伸和抓握,数据采集协议与上述数据库保持一致。采集过程如图 14 所示,受试者保持一定的坐姿,根据提示做相应的手势动作,每个手势重复 10 次,每次动作保持 5 s,休息 5 s。采集的表面肌电信号如图 15 所示,两条红线之间为手势动作段。




图 14 表面肌电信号的采集

Fig. 14 Acquisition of surface EMG signal




图 15 采集的表面肌电信号

Fig. 15 Surface EMG collected

按照 2.1 节中数据划分的方式,将 2/3 的手势重复划分为训练集,1/3 的手势重复划分为测试集,验证本文模型在实测数据中用户相关的手势识别效果。同时按照 2.2 节中方案 1 和方案 2 的方法验证领域自适应在实测数据中用户无关的手势识别效果。经测试,12 名用户的肌电数据在本文算法中基于用户相关的手势识别准确率为 98.25%,在未使用领域自适应的情况下用户无关的手势识别准确率仅为 6.57%,在应用领域自适应的条件下无关用户的手势识别准确率提升到了 77.06%,充分说明了本文算法的可行性。

3 结 论

MCI 广泛应用于各个领域,基于肌电信号的手势识别是其亟待解决的关键问题之一。本文提出的方法不仅提升了用户相关的手势识别准确率,而且提升了用户无关的手势识别准确率。

(1)在用户相关手势识别中,对表面肌电信号进行 SVM 分解并构建了利于手势识别的肌电图像,随后利用卷积神经网络进行手势识别,平均手势识别率分别达到了 99.28%、99.30%、98.39% 和 93.40%。实验结果表明,本文提出的方法在基于用户相关的肌电信号手势识别中效果良好。

(2)在用户无关手势识别中,利用迁移学习中的 AdaBN 技术解决用户之间肌电数据分布差异问题,减少了训练数据的同时提高了用户无关手势识别的准确率,平均手势识别率分别达到了 94.05%、92.60%、88.38% 和 70.03%,为模型的通用性提供了解决方案。

(3)实测数据进一步验证了本方法的有效性;用户相关和用户无关的手势识别的手势识准确率分别达到了98.25%和77.06%。同时实验中采用了平时生活中惯用的手指、手腕、抓握等手势动作为研究对象,有益于在实际应用中实现更为高效的控制。

参考文献:

- [1] GUO Weichao, YAO Pengfei, SHENG Xinjun, et al. An enhanced human-computer interface based on simultaneous sEMG and NIRS for prostheses control [C]//2014 IEEE International Conference on Information and Automation (ICIA). Piscataway, NJ, USA: IEEE, 2014: 204-207.
- [2] FAN Yuanjie, YIN Yuehong. Active and progressive exoskeleton rehabilitation using multisource information fusion from EMG and force-position EPP [J]. IEEE Transactions on Biomedical Engineering, 2013, 60(12): 3314-3321.
- [3] LI Yun, CHEN Xiang, ZHANG Xu, et al. A sign-component-based framework for Chinese sign language recognition using accelerometer and sEMG data [J]. IEEE Transactions on Biomedical Engineering, 2012, 59(10): 2695-2704.
- [4] CHENG Juan, CHEN Xiang, LU Zhiyuan, et al. Key-press gestures recognition and interaction based on SEMG signals [C]//International Conference on Multimodal Interfaces and the Workshop on Machine Learning for Multimodal Interaction. New York, USA: ACM, 2010: 36.
- [5] QI Wen, SU Hang, ALIVERTI A. A smartphone-based adaptive recognition and real-time monitoring system for human activities [J]. IEEE Transactions on Human-Machine Systems, 2020, 50(5): 414-423.
- [6] WEN Rong, TAY W L, NGUYEN B P, et al. Hand gesture guided robot-assisted surgery based on a direct augmented reality interface [J]. Computer Methods and Programs in Biomedicine, 2014, 116(2): 68-80.
- [7] VAN EDE F, NOBRE A C. Turning attention inside out: how working memory serves behavior [J]. Annual Review of Psychology, 2023, 74: 137-165.
- [8] KIELIBA P, CLOBE D, MAIMON-MOR R O, et al. Robotic hand augmentation drives changes in neural body representation [J]. Science Robotics, 2021, 6(54): eabd7935.
- [9] 丁其川,熊安斌,赵新刚,等.基于表面肌电的运动意图识别方法研究及应用综述 [J].自动化学报, 2016, 42(1): 13-25.
- [10] 胡旭晖,宋爱国,李会军.基于表面肌电图像的灵巧假手控制系统 [J].控制理论与应用, 2018, 35(12): 1707-1714.
- [11] FREITAS M L B, MENDES J J A Jr, DIAS T S, et al. Surgical instrument signaling gesture recognition using surface electromyography signals [J]. Sensors, 2023, 23(13): 6233.
- [12] FU Rongrong, ZHANG Baozhong, LIANG Haifeng, et al. Gesture recognition of sEMG signal based on GASF-LDA feature enhancement and adaptive ABC optimized SVM [J]. Biomedical Signal Processing and Control, 2023, 85: 105104.
- [13] WARIS A, NIAZI I K, JAMIL M, et al. Multiday evaluation of techniques for EMG-based classification of hand motions [J]. IEEE Journal of Biomedical and Health Informatics, 2019, 23(4): 1526-1534.
- [14] CÔTÉ-ALLARD U, FALL C L, CAMPEAU-LECOURS A, et al. Transfer learning for sEMG hand gestures recognition using convolutional neural networks [C]//2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC). Piscataway, NJ, USA: IEEE, 2017: 1663-1668.
- [15] JAFARZADEH M, HUSSEY D C, TADESSE Y. Deep learning approach to control of prosthetic hands with electromyography signals [C]//2019 IEEE International Symposium on Measurement and Control in Robotics (ISMCR). Piscataway, NJ, USA: IEEE, 2019: A1-4-1-A1-4-11.
- [16] CHUNG E A, BENALCÁZAR M E. Real-time hand gesture recognition model using deep learning techniques and EMG signals [C]//2019 27th European Signal Processing Conference (EUSIPCO). Piscataway, NJ, USA: IEEE, 2019: 1-5.
- [17] ATZORI M, COGNOLATO M, MÜLLER H. Deep learning with convolutional neural networks applied to electromyography data: a resource for the classification of movements for prosthetic hands [J]. Frontiers in Neurobotics, 2016, 10: 9.
- [18] ATZORI M, MÜLLER H. The ninapro database: a resource for sEMG naturally controlled robotic hand prosthetics [C]//2015 37th Annual International Con-

- ference of the IEEE Engineering in Medicine and Biology Society (EMBC). Piscataway, NJ, USA: IEEE, 2015: 7151-7154.
- [19] 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.
- CHEN Sijia, LUO Zhizeng. Research on gesture EMG recognition based on long short-term memory and convolutional neural network [J]. Chinese Journal of Scientific Instrument, 2021, 42(2): 162-170.
- [20] QURESHI M F, MUSHTAQ Z, REHMAN M Z U, et al. E2CNN: an efficient concatenated CNN for classification of surface EMG extracted from upper limb [J]. IEEE Sensors Journal, 2023, 23(8): 8989-8996.
- [21] LI Gongfa, BAI Dongxu, JIANG Guozhang, et al. Continuous dynamic gesture recognition using surface EMG signals based on blockchain-enabled internet of medical things [J]. Information Sciences, 2023, 646: 119409.
- [22] 李自由, 赵新刚, 张弼, 等. 基于表面肌电的意图识别方法在非理想条件下的研究进展 [J]. 自动化学报, 2021, 47(5): 955-969.
- LI Ziyu, ZHAO Xingang, ZHANG Bi, et al. Review of sEMG-based motion intent recognition methods in non-ideal conditions [J]. Acta Automatica Sinica, 2021, 47(5): 955-969.
- [23] GUO Weichao, SHENG Xinjun, LIU Jianwei, et al. Towards zero training for myoelectric control based on a wearable wireless sEMG armband [C]//2015 IEEE International Conference on Advanced Intelligent Mechatronics (AIM). Piscataway, NJ, USA: IEEE, 2015: 196-201.
- [24] XU Zhengyuan, YU Junxiao, XIANG Wentao, et al. A novel SE-CNN attention architecture for sEMG-based hand gesture recognition [J]. Computer Modeling in Engineering & Sciences, 2023, 134(1): 157-177.
- [25] XIONG Anbin, ZHAO Xingang, HAN Jianda, et al. An user-independent gesture recognition method based on sEMG decomposition [C]//2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Piscataway, NJ, USA: IEEE, 2015: 4185-4190.
- [26] ISON M R, ARTEMIADIS P. Beyond user-specificity for EMG decoding using multiresolution muscle synergy analysis [C]//ASME 2013 Dynamic Systems and Control Conference. New York, USA: ASME, 2013: V001T08A006.
- [27] 郑楠, 李玉榕, 张文萱, 等. 基于特定任务肌肉协同的用户无关肌电手势识别研究 [J]. 仪器仪表学报, 2021, 42(9): 253-261.
- ZHENG Nan, LI Yurong, ZHANG Wenxuan, et al. User-independent EMG gesture recognition based on task-specific muscle synergy [J]. Chinese Journal of Scientific Instrument, 2021, 42(9): 253-261.
- [28] KHUSHABA R N. Correlation analysis of electromyogram signals for multiuser myoelectric interfaces [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2014, 22(4): 745-755.
- [29] KANOGA S, HOSHINO T, ASOH H. Subject-transfer framework with unlabeled data based on multiple distance measures for surface electromyogram pattern recognition [J]. Biomedical Signal Processing and Control, 2022, 74: 103522.
- [30] ATZORI M, GIJSBERTS A, HEYNEN S, et al. Building the Ninapro database: a resource for the biorobotics community [C]//2012 4th IEEE RAS & EMBS International Conference on Biomedical Robotics and Biomechanics (BioRob). Piscataway, NJ, USA: IEEE, 2012: 1258-1265.
- [31] 李文武, 石强, 王凯, 等. 基于变分模态分解和深度门控网络的径流预测 [J]. 水力发电学报, 2020, 39(3): 34-44.
- LI Wenwu, SHI Qiang, WANG Kai, et al. Runoff prediction based on variational mode decomposition and deep gated network [J]. Journal of Hydroelectric Engineering, 2020, 39(3): 34-44.
- [32] DRAGOMIRETSKIY K, ZOZZO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [33] 龙明盛. 迁移学习问题与方法研究 [D]. 北京: 清华大学, 2014.
- [34] DU Yu, JIN Wenguang, WEI Wentao, et al. Surface EMG-based inter-session gesture recognition enhanced by deep domain adaptation [J]. Sensors, 2017, 17(3): 458.
- [35] LAI Zhiping, KANG Xiaoyang, WANG Hongbo, et al. Contrastive domain adaptation: a self-supervised learning framework for sEMG-based gesture recognition [C]//2022 IEEE International Joint Conference on Biometrics (IJCB). Piscataway, NJ, USA: IEEE, 2022: 1-7.
- [36] LI Yanghao, WANG Naiyan, SHI Jianping, et al. Revisiting batch normalization for practical domain adaptation [EB/OL]. (2016-11-08)[2023-06-01]. <https://arxiv.org/abs/1603.04779>.
- [37] 张龙娇, 曾晓勤. 基于深度神经网络的 sEMG 手势识别研究 [J]. 计算机工程与应用, 2019, 55(23): 2021, 42(9): 253-261.

113-119.
ZHANG Longjiao, ZENG Xiaoqin. Research on gesture recognition of sEMG based on deep neural network [J]. Computer Engineering and Applications, 2019, 55(23): 113-119.

[38] CHEN Hongfeng, ZHANG Yue, LI Gongfa, et al. Surface electromyography feature extraction via convolutional neural network [J]. International Journal of Machine Learning and Cybernetics, 2020, 11 (1): 185-196.

[39] KIM M, CHUNG W K, KIM K. Subject-independent sEMG pattern recognition by using a muscle source activation model [J]. IEEE Robotics and Automation Letters, 2020, 5(4): 5175-5180.

[40] KETTYKÓ I, KOVÁCS F, VARGA K Z. Domain adaptation for sEMG-based gesture recognition with recurrent neural networks [C]//2019 International Joint Conference on Neural Networks (IJCNN). Piscataway, NJ, USA: IEEE, 2019: 1-7.

(编辑 亢列梅 武红江)