

利用域对抗神经网络改进基于sEMG的经桡骨截肢者运动意图识别能力

刘 淇¹, 杨逸新¹, 李素姣^{1,2,3*}

¹上海理工大学健康科学与工程学院康复工程与技术研究所, 上海

²上海康复器械工程技术研究中心, 上海

³民政部神经功能信息与康复工程重点实验室, 上海

收稿日期: 2025年4月1日; 录用日期: 2025年5月1日; 发布日期: 2025年5月8日

摘 要

上肢肢体功能丧失在很大程度上降低了截肢患者生活质量, 为他们提供智能化、高性能的假肢有助于恢复患者所丧失的肢体功能。目前, 肌电控制假肢技术已然成为研究的热点。然而, 当前商用肌电假肢的弃用率较高, 主要原因包括缺乏准确的意图识别、不具备直观和方便的特性。文章深入研究了基于肌电信号的上肢运动模式识别技术, 特别关注于上肢截肢患者的需求, 旨在设计面向这一特定群体的智能识别方法, 以提高识别性能并促进肌电假肢系统的实际应用。并提出基于域对抗适应的动作识别算法, 针对不同个体的识别率差异问题, 通过域对抗训练和自适应批量归一化来最小化不同域之间的差异, 从而提高模型在目标域上的泛化能力和动作识别的精度。实验结果表明, 所设计算法优于微调和卷积神经网络, 在截肢受试者的识别任务中识别准确率最高达94.70%, 实时实验中平均动作完成率为83.48%。因此, 该算法能够有效地提升面向截肢受试者的识别性能。

关键词

表面肌电信号, 模式识别, 域适应, 经桡骨截肢

Improving sEMG-Based Recognition of Motor Intent in Transradial Amputees Using Domain Adversarial Neural Networks

Qi Liu¹, Yixin Yang¹, Sujiao Li^{1,2,3*}

¹Institute of Rehabilitation Engineering and Technology, School of Health Science and Engineering, University of Shanghai for Science and Technology, Shanghai

*通讯作者。

文章引用: 刘淇, 杨逸新, 李素姣. 利用域对抗神经网络改进基于sEMG的经桡骨截肢者运动意图识别能力[J]. 建模与仿真, 2025, 14(5): 44-55. DOI: 10.12677/mos.2025.145372

²Shanghai Engineering Research Center of Assistive Devices, Shanghai

³Key Laboratory of Neural-Functional Information and Rehabilitation Engineering of the Ministry of Civil Affairs, Shanghai

Received: Apr. 1st, 2025; accepted: May 1st, 2025; published: May 8th, 2025

Abstract

Loss of upper limb function largely reduces the quality of life of amputation patients, and providing them with intelligent, high-performance prostheses helps to restore the lost limb function of patients. At present, myoelectric control prosthesis technology has become a research hotspot. However, the current commercial myoelectric prostheses have a high abandonment rate, and the main reasons include the lack of accurate intent recognition and intuitive and convenient features. This paper presents an in-depth study of upper limb motion pattern recognition based on EMG signals, with a special focus on the needs of upper limb amputee patients, aiming to design intelligent recognition methods for this specific group to improve recognition performance and facilitate the practical application of EMG prosthetic systems. An action recognition algorithm based on depth domain adversarial adaptation is proposed. Aiming at the problem of recognition rate difference between different individuals, the differences between different domains are minimized by domain adversarial training and adaptive batch normalization, so as to improve the generalization ability of the model on the target domain and the accuracy of action recognition. The experimental results show that the designed algorithm outperforms the fine-tuning and convolutional neural network, and the recognition accuracy reaches up to 94.70% in the recognition task of amputee subjects. The average action completion rate in real-time experiments was 83.48%, respectively. Therefore, the algorithm can effectively improve the recognition performance of amputee subjects.

Keywords

sEMG, Pattern Recognition, Domain Adaptation, Transradial Amputee

Copyright © 2025 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

手是人体最多样化和最灵巧的部分，它可以通过采用各种不同的运动策略来执行各种活动，从而来与环境互动[1]。为了实现快速、直觉的假肢控制，人们提出了基于体表肌电模式识别的假肢控制方法。该方法利用模式识别技术解码使用者动作过程中产生的肌电信号，得到截肢者想要做的肢体运动，并根据识别出的运动操控假肢完成相应的动作。由于这种基于肌电模式识别的控制方案可以克服传统肌电假肢控制的不足，帮助截肢患者实现假肢的直觉、多自由度控制，成为了康复工程领域近几十年来的研究前沿和热点。但是目前为止，具有直觉操控的多自由度肌电假肢仍然没有实现临床应用。其主要原因在于截肢患者残留肌肉过少，不能为肌电假肢提供足够的控制信号，导致其实用性和稳定性不能满足临床应用的要求。

多通道 sEMG 的运动模式识别已被广泛研究为一项有效识别运动意图的分类任务[2]。大多数相关研究依赖于从完整受试者身上收集信号，与截肢者的信号相比，该信号的可及性和质量可以得到保证[3]。这种代理措施一方面有助于该领域的快速技术更新，不断地推出高性能的分类模型；然而，另一方面，

可能表现出过于乐观的分类性能[4]。根据 Atzori 等人[5]的研究,当应用相同的信号处理程序和分类器时,经桡骨截肢者的分类精度可能比完整受试者的分类准确率低 30%。同时,在提高上肢截肢者运动意图识别性能方面的努力有限[6]。更好地识别上肢截肢者的运动意图有助于提高其假肢的可用性。虽然截肢者可能有足够的动力采用肌电设备,因为他们能够恢复失去的运动功能,但目前的训练负担是采用一般消费类肌电设备的重大障碍。因此,对于减轻培训负担、提高采用率和扩大 EMG 手势识别的潜在用户群的问题需要被解决。

经典的深度学习假设训练数据和测试数据来自相同的基本分布。然而,这一假设经常被各种实际干扰所违反,这在深度学习应用中可称为域偏移。此外,作为一种生物电, sEMG 具有用户特定性和时变性,导致预训练模型在受试者之间的泛化能力较差。Campbell 等人[7]提出了一种基于批处理归一化和对抗迁移学习策略的神经网络架构。在提供少量目标用户数据的情况下,健康用户在 10 个手势上的分类准确率大于 86%,残疾用户在 10 个手势上的分类准确率大于 64%。Zhang 等人[8]提出了一种基于自适应采样方法的特征对齐迁移学习方法,该方法对自身采集的 6 个手势的平均准确率达到 90%左右。Ketykó 等人[9]提出的两步域自适应在 NinaPro DB-1 数据集上实现了约 65%的分类准确率。Xuan Zhang 等人[8]提出一种基于无监督域适应模型的自适应采样策略,在跨用户分类方式中的平均准确率为 $90.41\% \pm 14.44\%$ 。其次,为了实现更高、更一致的分类准确率,Côté-Allard 等人[10]采用渐进式神经网络架构进行参与者之间的迁移学习,其中每个参与者被视为一个源任务,与相同的非迁移方法相比,平均分类准确率提高了 5.67%。结合实际,Gregori 等人[11]曾尝试使用自适应学习方法将完整的受试者信息转移到截肢者身上,但是性能的改进被认为是超参数的改变引起的。

尽管基于肌电信号的上肢运动模式识别技术已经研究多年,并且已经在各方面取得了令人满意的成果,但是只有少量研究是针对截肢患者并考虑患者需求去进行的,大多数是以肢体完整受试者作为研究对象。因此,本文以上肢假肢作为研究载体,目的在于设计面向上肢截肢患者的运动模式智能识别方法,切实提高经桡骨截肢受试者的识别性能,从而推进肌电假肢系统的实际应用。针对不同个体和不同肢体位置的识别率差异较大,提出了基于域对抗神经网络(DANN)的动作识别算法。该算法遵循基线模型的网络拓扑和基本训练策略,并增加了域对抗训练。域对抗训练通过最小化不同域之间的差异来提高模型在目标域上的泛化性能,加入梯度反转层加速模型收敛。因此,该算法能够有效地减轻域偏移效应下模型性能下降的问题和重新校准的负担,并提高手势识别的精度。通过实验结果分析,验证了该算法可以有效提高不同个体识别的动作准确性,从肢体完整的受试者转移到截肢者有助于解决截肢者由于肌肉缺失而带来的数据稀缺问题。

2. 实验协议

2.1. 肌电信号采集实验方案

该实验共招募了 14 名受试者,其中包括 10 名健全受试者和 4 名经桡骨截肢者。在每次采集实验前均没有进行剧烈运动,手臂不存在肌肉拉伤、扭伤等问题。健康受试者平均年龄(22.60 ± 1.64)岁;男性 5 名,女性 5 名;均为右利手。截肢受试者 4 名,平均年龄为(37.75 ± 4.99)岁;截肢侧平均剩余长度大于健侧的 1/2,平均截肢年数为 12 年。两类受试者信息如表 1 和表 2 所示。

受试者被要求坐在桌子前面,通过调整座椅高度,将他们的前臂自然地垂直于地面。根据面前显示器中所播放的引导视频进行相应的手部动作,并以适中的力度保持肌肉收缩。当引导视频中显示恢复自然状态,受试者同样恢复到放松状态。实验共采集受试者 10 种前臂运动模式下的 sEMG 信号,为了避免偶发性错误同时提高 sEMG 信号采集的精确度,各运动重复 10 次,每次动作持续 5 秒,放松 2 秒后继续下一动作。不同动作之间休息 1 分钟。截肢受试者被要求在完成患肢动作的同时,使用健侧手臂镜像地同步完成动作以辅助患侧。为防止桌面挤压影响信号记录,位于支撑板中心槽中的传感器不接触支撑板,

保持悬浮状态。

根据 Nyquist-Shannon 采样定理，由于大约 95%的 sEMG 信号功率集中在 400~500 Hz [12]，传感器的最低采样频率必须是 sEMG 最高频率的两倍以上，以避免混叠现象。从无创、方便、对用户更友好的需求出发，本研究的信号采集实验使用 gForcePro + 肌电臂环作为采集设备。

采集的运动模式选取同时考虑到经桡骨截肢患者的患肢活动水平，通过总结在日常生活中出现频率较高的、具有功能性的动作，并结合已有研究[5] [13]，选取了十种静态手势。采集手势如图 1 所示。

Table 1. Limb complete subjects information

表 1. 肢体完整受试者信息

编号	性别	年龄	惯用手	前臂臂围(cm)	前臂长度(cm)
S1	女	21	右手	20	24
S2	男	21	右手	26	28
S3	男	22	右手	23	26
S4	女	22	右手	23	25
S5	女	22	右手	18	20
S6	男	25	右手	27	30
S7	男	24	右手	26	29
S8	女	23	右手	23	24
S9	男	24	右手	21	23
S10	男	22	右手	25	30

Table 2. Transradial amputation subjects information

表 2. 经桡骨截肢受试者信息

编号	年龄	截肢侧	截肢年数	截肢原因	截肢程度	截肢末端距肘部距离(cm)	健侧指尖距肘部距离(cm)
TR1	34	右	10	工伤	近腕	20 cm	44 cm
TR2	39	左	30	病理	近腕	35 cm	43 cm
TR3	45	左	3	工伤	近肘	12 cm	38 cm
TR4	33	左	5	工伤	近腕	23 cm	41 cm



握拳



拇指外展



伸拇指



伸食指



三指捏



五指抓



五指捏



捏食指



五指夹



捏三指

Figure 1. Schematic forearm gestures
图 1. 前臂手势示意图

2.2. 实时实验方案

实时性能评估实验招募了 2 名经桡骨截肢受试者，截肢受试者在离线实验表示可以做出相应的幻肢动作，所有受试者都签署了知情同意书。

实时性能评估实验手势使用十个静态手势。此外，每个用户都记录了保持放松姿势一分钟的数据，被标记为休息手势。使用重叠滑动窗口技术来提取分类器输入，滑动窗口长度 $W = 200 \text{ ms}$ ，步长为 $S = 100 \text{ ms}$ 。将 sEMG 信号分割成一系列 200 ms 的分析窗口，每 50 ms 产生一个手势类预测，在每个分析窗口中对肌电信号进行滤波和标准化，然后不间断地将窗口数据输入 DANN 算法。为了将活动段划分为一个整体，对各个窗口的标签执行多数投票。为了避免错误的分类，设置了一个置信度阈值 0.3，即如果没有标签分配给至少 30% 的窗口，即认为该段不包含任何所要预测的手势。

实时识别的实施过程如下：目标手势显示在屏幕上，受试者没有执行手势时分类器的输出状态是休息手势标签。受试者被指示跟随目标手势指导进行运动直到分类器输出正确的目标手势，当受试者能够将分类器识别出的手势保持 1 秒时，记为一次识别完成，直到完成第十次成功识别时该手势实验结束。在测试之前，每位受试者至少要花 5 分钟来熟悉每种手势的情况。

3. DANN 的算法框架

3.1. 肌电信号预处理

将 sEMG 信号转换成其他形式的输入是一个耗时的过程，比如时域或频域转换等，所以本文使用原始 sEMG 信号作为模型的输入，神经网络可以自动从原始数据中提取高层次内在特征。本文对 sEMG 信号的预处理步骤如图 2 所示。




Figure 2. Flowchart of sEMG signal preprocessing
图 2. sEMG 信号预处理流程图

降噪处理在抑制一部分噪声信号的同时也损失了肌电信号本身，降低了整体的信噪比，所以需要合理设计降噪算法，在过滤噪声的同时尽可能保存有效信号。通过巴特沃斯带通滤波器和 50 Hz 陷波器对采集信号中的 sEMG 进行了滤波处理。巴特沃斯滤波器通带频率范围为 20~500 Hz。

由于肌肉中运动单位激活的性质，测量的信号类似于零均值随机过程，其标准差与活动运动单位的数量和运动单位激活的速率成正比。将数据缩放到一个共同的参考值，从而在重复之间具有统计意义。本研究采用标准化对每一通道的数据 X 进行均值去除并按方差比例缩放，如式(1)所示：

$$X_{\text{norm}} = \frac{x_i - \mu}{\sigma} \quad (1)$$

其中 x_i 是原始数据集中的第 i 个数据点， μ 是原始数据集的均值， σ 是原始数据集的标准差。

sEMG 的采集过程是连续的，所采集的信号包括放松和动作信号，即非活动段数据和活动段数据[14]。但是用来分类的主要是能够表示肌肉活跃状态的活动段数据。目前常用的活动段检测方法有阈值检测法、移动平均法、短时傅里叶方法等考虑到适应不同动作信号变化、受试者生理差异等因素变化，以及由于受试者反应不同试次的完成时间之间的差异，本研究采用了自适应双阈值方法来检测肌电信号中的活动段。

1) 式(2)计算滑动窗口内的平均能量序列 S ，其中， L 是窗口长度， $E_{i,j}$ 是窗口内每个数据点的能量值。

$$S = \frac{1}{NL} \sum_{j=1}^L \sum_{i=1}^N E_{i,j} \quad (2)$$

2) 式(3)和(4)分别计算自适应阈值 Th_1 和 Th_2 , 其中, $\text{Median}(S)$ 是能量序列 $E_{i,j}$ 的中位数, $\text{StdDev}(S)$ 是能量序列 $E_{i,j}$ 的标准差, k 是用于调整阈值的常数, 设置为 0.5。

$$Th_1 = \text{Median}(S) + k \times \text{StdDev}(S) \quad (3)$$

$$Th_2 = \text{Median}(S) - k \times \text{StdDev}(S) \quad (4)$$

3) 将满足 $Th_2 < S_i < Th_1$ 条件的数据段视为活动段, 并确定活动段的起点和终点位置。其中, $(\text{start}_i, \text{end}_i)$ 表示第 i 个活动段的起点和终点位置, Th_2 和 Th_1 是根据平均能量序列 S 计算得到的双阈值。

$$\text{sEMG}_{\text{data}}(s, N, L, k) = \{(\text{start}_i, \text{end}_i) | Th_2 < S_i < Th_1\} \quad (5)$$

窗口宽度的选择对于数据处理非常重要。相邻的两个窗口之间有一定重叠的被定义为重叠分割法, 这种方法可以获得更多的数据段个数, 为后续分类器训练提供更多样本。窗口宽度表征了单次处理信号的长度, 长度越长越能整体表现肌电信号的特点, 但也会增加处理时长, 对计算机性能提出了更大挑战。而窗口宽度越小, 速度越快, 但可能提取的特征比较局部, 不能全面表达整体情况, 从而影响识别准确率。研究表明, 基于 sEMG 模式识别系统的最佳延迟在 100 ms~250 ms 之间。窗口太长会造成系统延迟, 太短的话可能没有足够的有用信息。因此, 本文将滑动窗口长度设定为 $W = 200$ ms, 步长为 $S = 100$ ms, 这个窗口长度配置可以保证连续的分类。每一个窗口就是一个 8×200 (通道数 $\times$ 滑动窗口长度) 维度的矩阵 $M = [M_1; \dots; M_8]$, 每个子向量 $M_i = [M_{i1}, \dots, M_{iW}]^T$ 表示第 i 个通道的信号。

3.2. 卷积神经网络模型

本文提出的 DANN 由几乎相同的两个流组成, 每个流都基于一个 CNN, 流之间的差异将在稍后的领域适应框架中展开。CNN 由两大部分组成, 即特征提取模块(Feature Extractor)和分类模块(Label Classifier)。前者包含两个区块, 除具体参数外基本相同, 每个区块封装一个卷积层, 然后是批量归一化、ReLU、dropout2d (设置为 $p = 0.5$) 和最大池化。同样, 后者包含三个区块, 每个区块封装完整的连接层, 然后是批量归一化(BN)、ReLU 和 dropout2d (设置 $p = 0.5$)。采用 ADAM 优化 CNN, 初始学习率为 0.001。为防止过拟合现象, 采用了批量归一化[15]、Dropout [16]。

3.3. DANN 框架




Figure 3. Overview of the DANN framework

图 3. DANN 框架概览

本文训练了一个共享所有预训练任务数据集的源网络，第二个网络的结构与源网络几乎相同。但两者的权重都是独立初始化和训练的。第二个网络称为目标网络。图 3 显示了最终提出的架构概览。

考虑一个分类问题，输入特征向量空间为 X ，输出空间的标签集为 $Y = \{1, 2, 3, \dots, N\}$ ， N 为动作标签数。假设 $\{X_s, Y_s\}$ 和 $\{X_t, Y_t\}$ 是定义在 $X \times Y$ 上的未知联合分布，分别称为源分布和目标分布。无监督域适应算法需要输入从 $\{X_s, Y_s\}$ 中采样的有标记源域数据和从边缘分布 $\{X_t\}$ 中采样的无标记目标域数据。源域和目标域的数据被输入特征提取器，然后由域分类器对特征进行分类。该架构有两个网络，每个网络由一个特征提取器和一个分类器组成。

特征提取器为 G_f ，用于接收经过预处理的 sEMG 特征向量 x_i ，并计算得到特征向量 f_i ，即，

$$f_i = G_f(x_i; \theta_f) \quad (6)$$

特征提取器得到的特征向量 f_i 映射到标签分类器 G_y 和域分类器 G_d ，即，

$$y_i = G_y(f_i; \theta_y) \quad (7)$$

$$d_i = G_d(f_i; \theta_d) \quad (8)$$

标签分类器和域分类器都是多层前馈神经网络，其参数分别称为 θ_y 和 θ_d ，在训练过程中，特征提取器的目标是在使领域分类器无法准确区分源领域和目标领域特征表征的同时，尽量减少分类误差。这样，特征提取器就能学习到对源域和目标域都具有良好泛化能力的特征表征。域对抗训练流程如图 4 所示。




Figure 4. Domain confrontation training process

图 4. 域对抗训练过程

采用对抗训练来同时最小化分类损失和最大化域分布的多样性，这使我们最终能够实现域不变模型。具体计算过程如算法 1 所示。

算法 1. 域对抗算法

输入：

- 1) 训练数据：带标签的源域数据 D_s ，不带标签的目标域数据 D_t 。
- 2) 学习率 η ，训练轮次 $T_{\max}$ ，批量轮次 $N_{\max}$ 。
- 3) 初始化超参数：特征提取器参数 θ_f ，标签分类器参数 θ_y ，域分类器参数 θ_d ，权重超参数 λ 。

输出：优化后的参数 θ_f 、 θ_y 和 θ_d 。

for $T = 1, 2, \dots, T_{\max}$ do

for $N = 1, 2, \dots, N_{\max}$ do

选取小批量： d_s, d_t from D_s, D_t

计算权重： θ_f, θ_y 和 θ_d

续表

计算损失:

$$\text{Loss}_y(\theta_f, \theta_y) = \frac{1}{n} \sum_{(x,y) \in d_s} y^T \log G_y(G_f(x; \theta_f); \theta_y)$$

$$\text{Loss}_d(\theta_f, \theta_d) = \frac{1}{m} \sum_{(x,y) \in d_r} y^T \log G_d(G_f(x; \theta_f); \theta_d)$$

计算最终损失:

$$\text{Loss} = \text{Loss}_y - \lambda \text{Loss}_d$$

参数更新:

$$\theta_f = \theta_f - \eta \nabla \text{Loss}(\theta_f)$$

$$\theta_y = \theta_y - \eta \nabla \text{Loss}(\theta_y)$$

$$\theta_d = \theta_d - \eta \nabla \text{Loss}(\theta_d)$$

End for

3.4. 评估指标

为验证模型的性能,本研究使用的量化评估指标包括准确率(Accuracy),其表示正确预测占总预测的比例。指标参数和误差信息均以百分比表示。

$$\text{准确率Accuracy} = \frac{\text{正确预测数}}{\text{总预测数}} \times 100\% \quad (9)$$

本实验确定了三个指标来评估 DANN 的实时识别性能,如表 3 所示。第一个是运动完成率,它是已完成的手势识别与完成时间内的手势识别总数量之间的比率;第二个是运动完成时间,它是从开始运动到实验完成的时间;第三个是运动选择时间,它是正确选择目标手势运动所需的时间,定义为从运动开始到第一次正确分类的时间。

Table 3. Evaluation indicators

表 3. 评估指标

指标	描述
运动完成率	已完成的手势识别与完成时间内的手势识别数量之间的比率
运动完成时间	从开始运动到实验完成的时间
运动选择时间	从实验开始到第一次正确识别出手势的时间

运动完成率计算公式如下:

$$\text{运动完成率} = \frac{10}{N} \times 100\% \quad (10)$$

4. 结果与分析

4.1. 卷积神经网络识别结果

图 5 为所有受试者的识别准确率统计。我们提出的卷积神经模型在健康受试者中的识别率均大于 90%,最高识别准确率为 97.38%,但是经桡骨截肢受试者的识别准确率低于 90%,使用所有受试者的数

据进行训练的结果为 88.42%，说明模型能够识别完成前臂基础动作的识别任务，然而前臂截肢受试者的识别准确率相对较低。




Figure 5. Recognition accuracy for each subject

图 5. 各受试者识别准确率




Figure 6. Confusion matrix for baseline model

图 6. 基线模型的混淆矩阵

图 6 为健康受试者的混淆矩阵。混淆矩阵中，行与列分别表示实际类别和预测类别，矩阵对角线反映出实际与预测之间的匹配程度，该元素的颜色越深表示该运动模式类别分类性能越好。CNN 模型的分类中，健康受试者动作识别准确率均达到 95% 以上。

综上所述，卷积神经网络作为基线模型在识别健康受试者的前臂基础动作方面表现出色，但在面对肢体截肢的情况下识别准确率有所下降，因此需要引入域适应结构，以提高模型的适用性和性能。

4.2. DANN 域适应结果

根据上一节中提到的两类受试者识别效果的差异，经桡骨受试者的识别准确率由于截肢者的信号质量有限而相对较低。这种数据的稀有性不可避免地给为残障人士构建可靠、个性化的深度学习模型带来了问题。为了解决这个问题，我们提出了使用 DANN 的方法。首先在肢体完整受试者身上训练卷积神经网络作为基线模型，然后用截肢者数据进行域适应。我们还与微调这种迁移学习方式进行了对比。实验的目的是提高截肢受试者 sEMG 动作的识别准确率。并以基线模型训练，每一位受试者的数据作为一个单一域，在训练源网络的过程中，我们使用奇数重复次数进行训练，而偶数重复次数则用于测试。在源网络训练的过程中，分别使用每一名肢体完整受试者对应的 sEMG 动作数据作为输入，进行交叉验证。而在测试 DANN 时，我们仅仅使用了截肢受试者的第 1 次和第 2 次重复作为目标域进行再训练，其余 8 次重复用于测试。

识别结果如图 7 所示，得益于使用非截肢者数据进行域训练，4 名经桡骨截肢受试者的识别准确率得到了显著提升，并且使用仅通过微调后的结果。4 名受试者的识别准确率分别为 $94.70\% \pm 0.57\%$ (TR1)、 $92.71\% \pm 0.81\%$ (TR2)、 $94.59\% \pm 0.39\%$ (TR3)、 $94.69\% \pm 1.41\%$ (TR4)，其识别准确率均大于 90%。相比于仅使用 CNN 和微调的方式进行训练，分别平均提升了 13.45% 和 4.01%。虽然平均只提升了 13.45%，但是使用两次重复的数据就可以实现两类受试者的准确率达到理想水平。这一结果也表明，DANN 通过利用肢体完整受试者的信息进行领域适应，相较于仅使用截肢受试者本身的数据进行训练，更能有效实现肌电接口的改进。




Figure 7. Results of domain adaptation in transradial amputation subjects

图 7. 经桡骨截肢受试者域适应结果

4.3. 实时识别结果

运动完成率是一个重要的指标，它代表了鲁棒性的衡量标准，需要非常高的成功率才能允许足够的功能实现并防止用户感到停滞。表 4 为 10 个前臂手势在运动完成时间内的运动完成率，结果为所有受试者运动完成率的均值。可以看出，10 个手势之间运动完成率存在一定的差别，部分精细手指动作识别效果较差。同时需要五指同时参与的动作容易相互混淆，所以五指抓、五指捏、五指夹三个动作识别效果很差。从开始识别到完成十次成功的手势识别时间在 18 秒~33 秒内，同样地，五指同时参与的动作所需完成时间更长。大多数手势运动被快速选择，运动选择时间多为 1 秒。由最终的结果可以看出，DANN 可以满足经桡骨截肢受试者基本的日常动作识别任务。

Table 4. Results of real-time recognition of each movement in subjects with transradial amputates
表 4. 经桡骨截肢受试者各动作实时识别结果

动作类别	动作完成率	动作完成时间(秒)	动作选择时间(秒)
握拳	100.00%	24.00	2.00
拇指外展	91.41%	18.00	1.00
伸拇指	100.00%	19.00	3.00
伸食指	96.97%	21.00	1.00
三指捏	100.00%	18.00	1.00
五指抓	65.03%	30.00	1.00
五指捏	49.62%	33.00	8.00
捏食指	90.91%	19.00	2.00
五指夹	46.97%	32.00	1.00
捏三指	90.91%	20.00	1.00

5. 总结

本研究面向上肢截肢患者，聚焦解决其前臂动作识别难题，并引入 DANN 算法框架，以提升截肢者使用肌电接口的准确性和实时性。还提出了域对抗适应的动作识别算法，旨在解决不同个体之间的识别率差异问题。通过引入域对抗训练技术，成功减少了不同域之间的差异，从而提高了模型的泛化能力和动作识别精度。实验结果验证了使用肢体完整受试者的信息训练截肢者获得更准确的运动分类模型的可行性，最终两类截肢受试者的识别准确率均大于 90%。本文的研究实现了经桡骨截肢患者的动作识别准确性，在基础的手、腕动作上表现优秀，也具备实时性能。但是研究中还存在截肢受试者数量有限、训练场景单一等问题，这些将是我们今后工作的方向。

基金项目

国家重点研发计划项目(No. 2020YFC2007902)。

参考文献

- [1] Feix, T., Romero, J., Schmiedmayer, H., Dollar, A.M. and Kragic, D. (2016) The GRASP Taxonomy of Human Grasp Types. *IEEE Transactions on Human-Machine Systems*, **46**, 66-77. <https://doi.org/10.1109/thms.2015.2470657>
- [2] Schultz, A.E. and Kuiken, T.A. (2011) Neural Interfaces for Control of Upper Limb Prostheses: The State of the Art and Future Possibilities. *PM&R*, **3**, 55-67. <https://doi.org/10.1016/j.pmrj.2010.06.016>

- [3] Kim, M., Chung, W.K. and Kim, K. (2020) Subject-Independent sEMG Pattern Recognition by Using a Muscle Source Activation Model. *IEEE Robotics and Automation Letters*, **5**, 5175-5180. <https://doi.org/10.1109/lra.2020.3006824>
- [4] Al-Timemy, A.H., Khushaba, R.N., Bugmann, G. and Escudero, J. (2016) Improving the Performance Against Force Variation of EMG Controlled Multifunctional Upper-Limb Prostheses for Transradial Amputees. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, **24**, 650-661. <https://ieeexplore.ieee.org/document/7131549>
- [5] Atzori, M., Gijsberts, A., Castellini, C., Caputo, B., Hager, A.M., Elsig, S., *et al.* (2014) Electromyography Data for Non-Invasive Naturally-Controlled Robotic Hand Prostheses. *Scientific Data*, **1**, Article No. 140053. <https://doi.org/10.1038/sdata.2014.53>
- [6] Zhai, X.L., Jelfs, B., Chan, R.H.M. and Tin, C. (2017) Self-Recalibrating Surface EMG Pattern Recognition for Neuroprosthesis Control Based on Convolutional Neural Network. *Frontiers in Neuroscience*, **11**, Article 379. <https://www.frontiersin.org/journals/neuroscience/articles/10.3389/fnins.2017.00379/full>
- [7] Campbell, E., Phinyomark, A. and Scheme, E. (2021) Deep Cross-User Models Reduce the Training Burden in Myoelectric Control. *Frontiers in Neuroscience*, **15**, Article 657958. <https://www.frontiersin.org/journals/neuroscience/articles/10.3389/fnins.2021.657958/full>
- [8] Zhang, X., Zhang, X., Wu, L., Li, C., Chen, X. and Chen, X. (2022) Domain Adaptation with Self-Guided Adaptive Sampling Strategy: Feature Alignment for Cross-User Myoelectric Pattern Recognition. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, **30**, 1374-1383. <https://doi.org/10.1109/tnsre.2022.3173946>
- [9] Ketykó, I., Kovács, F. and Varga, K.Z. (2019) Domain Adaptation for sEMG-Based Gesture Recognition with Recurrent Neural Networks. 2019 *International Joint Conference on Neural Networks (IJCNN)*, Budapest, 14-19 July 2019, 1-7. <https://ieeexplore.ieee.org/abstract/document/8852018>
- [10] Cote-Allard, U., Fall, C.L., Drouin, A., Campeau-Lecours, A., Gosselin, C., Glette, K., *et al.* (2019) Deep Learning for Electromyographic Hand Gesture Signal Classification Using Transfer Learning. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, **27**, 760-771. <https://doi.org/10.1109/tnsre.2019.2896269>
- [11] Gregori, V., Gijsberts, A. and Caputo, B. (2017) Adaptive Learning to Speed-Up Control of Prosthetic Hands: A Few Things Everybody Should Know. 2017 *International Conference on Rehabilitation Robotics (ICORR)*, London, 17-20 July 2017, 1130-1135. <https://doi.org/10.1109/icorr.2017.8009401>
- [12] Clancy, E.A., Morin, E.L. and Merletti, R. (2002) Sampling, Noise-Reduction and Amplitude Estimation Issues in Surface Electromyography. *Journal of Electromyography and Kinesiology*, **12**, 1-16. [https://doi.org/10.1016/s1050-6411\(01\)00033-5](https://doi.org/10.1016/s1050-6411(01)00033-5)
- [13] Campbell, E., Cameron, J.A.D. and Scheme, E. (2020) Feasibility of Data-Driven EMG Signal Generation Using a Deep Generative Model. 2020 *42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, Montreal, 20-24 July 2020, 3755-3758. <https://doi.org/10.1109/embc44109.2020.9176072>
- [14] Li, G.F., Li, J.H., Ju, Z.J., Sun, Y. and Kong, J.Y. (2019) A Novel Feature Extraction Method for Machine Learning Based on Surface Electromyography from Healthy Brain. *Neural Computing and Applications*, **31**, 9013-9022. <https://link.springer.com/article/10.1007/s00521-019-04147-3>
- [15] Ioffe, S. and Szegedy, C. (2015) Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. arXiv: 1502.03167. <http://arxiv.org/abs/1502.03167>
- [16] Gal, Y. and Ghahramani, Z. (2016) Dropout as a Bayesian Approximation: Representing Model Uncertainty in Deep Learning. arXiv: 1506.02142. <http://arxiv.org/abs/1506.02142>