

DOI: 10.13382/j.jemi.B2407298

多源域迁移学习的肌电-惯性特征融合及手势识别*

谢平^{1,2} 赵连洋¹ 张艺滢³ 徐猛¹ 江国乾¹ 陈杰⁴

(1.燕山大学电气工程学院 秦皇岛 066000;2.河北省智能康复及神经调控重点实验室 秦皇岛 066000;
3.北京理工大学设计与艺术学院 北京 100081;4.燕山大学体育学院 秦皇岛 066000)

摘要:在跨用户手势识别研究中,针对单源域迁移学习存在的负迁移和模型泛化性能差的问题,本研究创新性地提出了一种基于肌电-惯性特征融合的多源域迁移学习策略,关键创新点在于整合多个源域的数据,并在此基础上采用域特有特征对齐与域分类器对齐的技术手段。这一方法旨在强化模型在不同用户间的手势识别性能,进而显著提升跨用户手势识别系统的准确性。首先,引入长短时记忆(long short-term memory, LSTM)网络模型,提取肌电-惯性信息的平均绝对值、方差、峰值等时序特征;其次进行域特有特征对齐与域分类器对齐,利用多个源域数据完成对目标域的特征提取;最后融合分类损失、域特有特征差异损失和域分类器差异损失3个损失函数,协同优化整体损失。实验结果表明,所提方法与单源域、源域组合等多种传统方法相比,识别平均率有所提高,在NinaPro DB5数据集上,目标用户的手势识别平均准确率达到80%以上。

关键词:肌电-惯性信号;跨用户手势识别;多源域迁移学习;长短时记忆网络;特征对齐

中图分类号: TP391.4 **文献标识码:** A **国家标准学科分类代码:** 310.61

Multi-source domain transfer learning for electromyography-inertial feature fusion and gesture recognition

Xie Ping^{1,2} Zhao Lianyang¹ Zhang Yiying³ Xu Meng¹ Jiang Guoqian¹ Chen Jie⁴

(1. College of Electrical Engineering, Yanshan University, Qin Huangdao 066000, China; 2. Hebei Key Laboratory of Intelligent Rehabilitation and Neuroregulation, Qin Huangdao 066000, China; 3. School of Design & Arts, Beijing Institute of Technology, Beijing 100081, China; 4. College of Physical Education, Yanshan University, Qin Huangdao 066000, China)

Abstract: In the realm of cross-user gesture recognition research, addressing the challenges of negative transfer and subpar model generalization observed in single-source domain transfer learning, this study presents a multi-source domain transfer learning strategy centered around the fusion of EMG and inertial features. The pivotal innovation lies in amalgamating data resources originating from diverse source domains, and subsequently employing techniques for domain-specific feature alignment and domain classifier alignment. The primary objective of this approach is to bolster model performance in gesture recognition across different users, thus significantly enhancing the accuracy of cross-user gesture recognition systems. Initially, the long short-term memory (LSTM) network model is introduced to extract time series features, encompassing metrics such as average absolute value, variance, and peak value derived from EMG and inertia data. Subsequently, domain-specific feature alignment and domain classifier alignment procedures are executed, facilitating feature extraction within the target domain utilizing data from multiple source domains. Lastly, the fusion of three loss functions—classification loss, domain-specific feature difference loss, and domain classifier difference loss—is undertaken to collectively optimize the overall loss. The experimental results demonstrate that the proposed method exhibits an improvement in average recognition rate compared to various traditional methods, such as single-source domain and source domain combination approaches. On the NinaPro DB5 dataset, the average gesture recognition accuracy for the target users exceeds 80%.

Keywords: EMG inertial signal; cross user gesture recognition; multi-source transfer learning; long short-term memory; feature alignment

0 引言

随着人机交互技术的日益成熟,使用 sEMG (surface electromyography) 控制智能假手成为可能^[1], 手势识别技术已在人机交互领域表现出重要的研究价值和应用前景,如基于手势识别远程控制的家用服务机器人^[2], 康复机器人的交互控制^[3], 以及工业机械臂的手势识别控制等。随着可穿戴技术的发展,以及肌电与惯性信号可以直接体现手部及肢体的动作状态和姿态信息的优势,基于肌电-惯性等生理信号的特征分析相关技术得以广泛应用。Atzori 等^[4]使用简单的 CNN (convolutional neural networks) 模型在 NinaPro DB1 数据集上获得 $66.59\% \pm 6.4\%$ 的识别率,超过了传统的机器学习方法,证明深度学习适合应用于肌电信号的手势识别。Qiu 等^[5]开发了基于惯性传感器的视觉康复训练游戏和可定制的扩展康复项目,通过对骨骼追踪准确评估人体姿势来检测身体残疾和分析康复过程,取得了理想效果。李自由等^[6]提出肌电信号和惯性信号融合框架能有效地提高手势识别精度。sEMG 手势识别的关键在于信号预处理与分类模型,二者分别用于去除 sEMG 噪声干扰和预测样本类别^[7]。然而由于手势动作相对精细,手势识别精度相对难以提高,为此本文结合肌电-惯性信息融合进行跨被试手势识别学习。

在单源域自适应研究中代表性研究有: Patricia 等^[8-9]使用迁移学习方法对跨用户动作识别进行研究,通过少量的新用户数据来更新已知用户的识别模型权重因子,使模型能够快速适应于新用户数据。胡学政等^[10]采用自适应因子执行动态分布对齐方法,动态调整数据不同分布差异下边缘分布和条件分布的相对重要性。Ison 等^[11]通过提取肌肉的协同特征作为个体之间的通用特征,以此提高跨用户的识别效果。Jiang 等^[12]通过使用相关性数据加权校正方法评估已知用户数据和未知用户数据之间的权重,实现模型在跨用户间的性能提升。上述研究方法,一定程度上提高了跨用户识别准确率,但存在以下局限:1) 大都通过单一受试者进行单源迁移学习,由于个体差异性的存在,不同受试者对于同一目标被试的迁移学习结果差异较大,无法确保对目标用户手势识别的准确性。2) 领域自适应方式是通过将源域和目标域数据借助共有的特征提取器映射至同一个特征空间内,在此空间内计算源域和目标域间的分布差异从而学习域不变特征。然而,在实际使用过程中,发现由于域差异性的存在,无法通过公共的特征提取器获得每个域的全部信息,无法完全对齐两个域^[13]。

为解决单源域识别效果较差问题,研究者将迁移学习工作侧重于重新加权源数据将多个源域组合为一个新

的源域,以便有用的源域知识可以有效地迁移到目标域^[14-16]。基于特征的源域组合迁移学习能够减小领域之间分布差异,但是借助最小化度量距离得到的域不变特征,经常会出现特征失真的状况。并且特征失真很可能会破坏源域和目标域的内在分类结构,进而会降低对目标样本的分类性能^[17-18]。

综上,由于不同用户的动作数据分布差异不可避免,使用单源域迁移学习与源域组合迁移学习的方法在跨用户手势识别中仍存在一定局限性。为此,本文在上述研究基础上提出一种基于多源域迁移学习的跨用户手势识别方法,通过在特征提取器后设置域特征提取器,在获得该域的特有信息后进行对齐,以此实现多源的每个源域特征和目标域特征对齐。同时通过分类器对齐最小化目标域数据在多个源域分类器结果之间的差异来对齐分类器,实现提高目标域的分类边界数据识别效果。

1 多源域迁移学习网络模型

在肌电-惯性信息融合学习中,不同用户生理信息存在个体性差异性,导致跨用户手势识别中存在准确率低,泛化能力差等问题。由于不同人之间由于肌肉的发达程度和肌肉收缩方式不同,执行相同动作时产生的肌电信号会存在差异^[19-20],因此限制了迁移学习模型在多个用户之间的实用性。为此,相关学者运用领域自适应方法进行跨用户迁移学习,如图 1 所示,其中包括单源域自适应与多源域自适应迁移学习两方面。




图 1 多源域自适应示意图

Fig. 1 Multi-source domain adaptive diagram

1.1 多源域迁移学习网络模型基本结构

对预处理后的肌电与惯性源域信号 X_{s1} 、 X_{s2} 、 X_{s3} 、 $\dots$ 、 X_{sn} 和目标域 X_t 通过共有特征提取器 F 提取时序特征,之后通过域特有特征提取器 H_{s1} 以及域分类器 C_{s1} ,其中 X_n 为肌电惯性信号, F 选用长短时记忆网络, H_{s1} 选用全连接层, C_{s1} 选用 Softmax 分类器。利用多个源域数据完成对目标域的信息获取,最后调整分类损失、域特有特征差异损失和域分类器差异损失权重完善模型,具体模型如图 2 所示。




图2 多源域迁移学习网络结构

Fig. 2 Multi-source domain transfer learning network structure

1.2 数据预处理

数据集中肌电信号包含噪声的干扰,噪声来源包括电流或电气设备,为确保信号数据的准确,需消除信号中的噪声干扰。常见的干扰包括运动伪迹、工频噪声等,对此本文采用陷波滤波器和巴特沃斯滤波器对信号进行预处理。选择应用一个 50 Hz 陷波滤波器,去除工频信号干扰,同时采用三阶巴特沃斯滤波器,截止频率为 2 Hz,采样率为 200 Hz,有效地降低了噪声成分。

1.3 共有特征提取

多源域迁移学习的公共特征提取器用于将源域和目标域数据从原始特征空间映射到公共共享潜在空间,然后提取所有域的公共表示。该模块可以帮助提取一些低级别的域不变特征。

本文模型利用一个长短期记忆网络作为提取所有域特征,将数据从原始数据映射到公共的特征空间内。肌电信号和惯性信号属于时间序列数据,时间序列数据是指随时间变化的观测值,其数学表示为 $E = \{X_1, X_2, \dots, X_n\}$,表示数据集中有 n 条序列。对于肌电、惯性信号等一维时间序列,其表示方法为:

$$X_i(t) = x_1, x_2, \dots, x_{i-1}, i = 1 \quad (1)$$

式中: $X_i(t)$ 表示序列长度为 t 的时间序列数据中的第 i 个序列点。

共有特征提取器通过 LSTM 方法,获取肌电信号和惯性信号的时间序列特征。LSTM 由遗忘门、更新门和输出门组成。LSTM 的遗忘门使用 $\tanh$ 函数作为最终输出决定了上一个细胞状态 C_{i-1} 是否被遗忘,当 f_i 为 0 时遗忘;为 1 时保留;数学表达式如式(2)所示。

$$f_i = \text{sigmoid}(w_f * [h_{i-1}, x_i] + b_i) \quad (2)$$

式中: W_f, b_i 为模型权重和偏置, $*$ 代表卷积运算。

最新的细胞状态 C_i 是由上一个细胞状态 C_{i-1} 和新

的待定细胞状态一起决定的; f_i 和 i_i 是 C_{i-1} 和的权重系数项,是细胞的更新或遗忘的体现,数学表达式如式(3)~(5)所示。

$$i_i = \text{sigmoid}(w_i * [h_i - 1, x_i] + b_i) \quad (3)$$

$$\tilde{C}_i = \tanh(w_c [h_i - 1, x_i] + b_c) \quad (4)$$

$$C_i = f_i * C_{T-1} + i_i * \tilde{C}_i \quad (5)$$

式中: i_i 为输入门, C_{T-1} 为上个细胞状态;

输出门负责确定当前细胞状态 C_i 的输出值 H_i ,数学表达式如式(6)和(7)所示。

$$o_i = \text{sigmoid}(w_o * [h_i - 1, x_i] + b_o) \quad (6)$$

$$h_i = o_i * \tanh(C_i) \quad (7)$$

输入门与输出门控制着网络的输入与输出,遗忘门控制着记忆单元,决定了时间信息保留或者遗忘。因而, LSTM 能够有选择地完成对时间信息记忆或保留,实现对连续信息的长期记忆,以及自动提取有效时序特征。

1.4 域特征提取、融合

为了进一步提取源域和目标域的共有特征,本文对每个源域分别设置域特征提取器,进而获得每个源域特有特征,以此实现将各个源域数据映射到每个域特定的特征空间。领域特定特征提取器遵循通用特征提取器。在获得所有域的特征后,本文建立了 N 个全连接层来对应 N 个源域。对于每对源域和目标域,分别通过相应的特定域特征提取器将数据映射到一个唯一的潜在空间,然后获得每个分支中的特定域的特征。为了应用领域自适应并使两个域在潜在空间中接近,本文选择 CORAL 来估计这两个域之间的距离。在训练过程中,减少了 CORAL 损失,缩小了特征空间中的源域和目标域,有助于对目标域进行更好的预测。本模块旨在学习多个特定领域的功能。全连接层作为每个域域特征提取器,本文中使用两个全连接层对数据升降维。其中,第 1 个全连

接层实现了降维操作,将特征图的通道维度从 C 降为 C/r ,其中 C 代表通道, r 是可以改变的超参数,在此全连接层后使用 ReLU 作为激活函数;第 2 个全连接层实现了升维操作,将特征图的通道维度从 C/r 重新升至 C ,在此全连接层后使用 Sigmoid 作为激活函数,限制其输出范围为 0~1。如图 3 所示,文中通道特征经过输入为 19,输出为 64 的全连接层升维操作后,再经过输入为 64,输出为 19 的全连接层进行降维,获得通道特征信息权重,通过

与原始特征相乘,获得特征通道融合的信号特征图,输出尺寸不变,同时将获得的肌电高级特征与惯性高级特征进行特征融合。其中使用全连接层的原因是:特征通道的权重是需要所有的训练数据样本训练到的,而不是仅通过观测若干个数据进行确定,使用全连接层代替固定参数,可以通过训练数据学习到这个权重,实现基于全训练样本下的特征通道权重确定。




图 3 域特有特征提取与融合

Fig. 3 Domain-specific feature extraction and fusion

1.5 域分类器分类

特定领域分类器使用从域特征提取器中提取的特征来预测结果。 C_{s_i} 是一个多输出组件,它由 N 个 Softmax 分类器组成,并对应于特定的源域。域特有特征 $H_i(F(x_s^i))$ 被用于训练领域特定分类器 C_i 。每个分类器 C_i 接收域特有特征 $H_i(F(x_s^i))$ 并输出预测结果 $C_i(H_i(F(x_s^i)))$ 。在本文中,域分类器以交叉熵的形式作为输出,其损失函数为:

$$L_{cls} = \sum_{i=1}^N E_{x \sim X_s^i} J(C_i(H_i(F(x_s^i))), y_s^i) \quad (8)$$

由于每个源域都被分配了域特定分类器,对于目标域数据,每个域特定分类器给出其自己的决策,并且对于相同的目标数据给出 N 个输出。这项工作将所有分类器的决策平均为目标域决策。在每次迭代中,在已经处理了源域 X_i 的所有操作之后。依次执行源域 X_{i+1} ,直到最后一个源域 X_n 的操作处理结束。然后网络进入下一次迭代。

1.6 多源迁移学习对齐

1) 域特征对齐

为了实现域特有特征对齐,使用 CORAL 作为对域特征之间分布差异的度量函数,该方法是一种使用二阶统计量对齐方法,即通过计算协方差来计算特征之间的距离,该方法的差异度量为:

$$L_{CORAL} = \frac{1}{4d^2} Cov_s - Cov_t^2 \quad (9)$$

$$Cov_s = \frac{1}{n_s - 1} (D_s^T D_s) - \frac{1}{n_s} (I^T D_s)^T (I^T D_s) \quad (10)$$

$$Cov_t = \frac{1}{n_t - 1} (D_t^T D_t) - \frac{1}{n_t} (I^T D_t)^T (I^T D_t) \quad (11)$$

其中, Cov_s 代表源域特征的协方差矩阵, Cov_t 代表目标域特征的协方差矩阵, I 代表所有元素为 1 的列向量, d 代表特征层神经元个数, $\|Cov_s - Cov_t\|^2$ 代表协方差距离的 F 范数, D_s 代表源域数据特征, D_t 代表目标域数据特征, n_s 代表源域数据量, n_t 代表目标域数据量。通过计算源域特征和目标域特征的协方差距离可以衡量其分布差异。

2) 域分类器对齐

域分类器是在多个不同源域数据进行训练的,因此对目标样本特别是分布在类边界的目标源域数据发生误判。为了实现域特征对齐,本文利用目标域在所有域分类器上输出差异绝对值作为对齐距离函数:

$$L_{disc} = \frac{2}{N \times (N - 1)} \sum_{j=1}^{N-1} \sum_{i=j+1}^N E_{x \sim X_i} \times [|C_i(H_i(F(x_k))) - C_j(H_j(F(x_k)))|] \quad (12)$$

训练网络的同时,网络不断收集来自新用户的新传入数据,同时使用这些未标记的新用户数据和标记的源域数据进行域自适应。通过上述介绍,本文的多领域迁移学习

方法的损失由 3 个部分组成,分别为分类损失、域特有特征差异损失和域分类器差异损失。其总损失公式为:

$$L = L_{cls} + \lambda L_{CROAL} + \gamma L_{disc}$$

(13)

2 结果与讨论

2.1 实验数据集

本文采用 NinaPro DB5 公开数据库^[21],其中 NinaPro

DB5 使用两个 MYO 臂环共采集 16 个通道肌电信号以及三轴惯性信号,总计 19 个通道数据。

数据集共采集 10 名健康受试者 53 种手势,每个受试者对每个手势重复 6 次,每个动作维持 5 s,每个动作执行完休息 3 s。获取的手势包含 12 个精细手指动作、17 个手腕动作、23 个抓握手势和静息手势动作,每个受试者共计做 318 个手势动作。53 种手势动作,佩戴方式以及实验范式如图 4 所示。




图 4 NinaPro DB5 中 53 种手势动作、传感器佩戴方式与实验范式

Fig. 4 The 53 hand gestures, sensor placement methods, and experimental paradigms in NinaPro DB5

训练选择 NinaPro DB5 数据 260 ms 动作数据,共 52 个点作为滑动窗口长度,使用 20 ms 动作数据,共 4 个点作为滑动窗口的移动步长。

2.2 实验结果

首先图 5 表明了使用本文方法在训练过程中的损失函数与识别准确率随着训练的迭代次数变化的变化曲线,图 5(a)为训练过程的损失,图 5(b)为模型在目标域的识别准确率。从图中可以看出随着训练次数增加,模型在目标域准确率波动上升,而后随着训练次数的继续增加,模型在目标域准确率会发生小幅下降。

如图 5 所示,随着模型训练次数的增加,模型损失函数数值逐渐下降,模型在目标受试者上的识别精度也随之提升,但是随着训练次数的增加,模型精度发生下降。其原因是由于损失函数中包含分类损失,因此随着模型参数不断优化,模型发生过拟合。

为了更好的说明本文使用方法的有效性,表 1 给出了使用多源域迁移学习前后,模型应用于新用户时手势识别的准确率。对于同一个人,将手势的第 1、2、3、4 次动作手势作为训练数据,手势动作的第 5、6 次手势动作作为评估和测试数据,其精度最高值为 98.78%。通过本




图 5 模型在目标域识别准确率随迭代次数的变化

Fig. 5 The change of recognition accuracy of the model in the target domain with iteration number

文的多源迁移学习方法进行模型迁移,可以将模型在目标域的精度提高至 80.81%,相比于未迁移,提高了 21.61% 识别准确率。

表 1 领域自适应前后手势识别精度对比

Table 1 Domain adaptation's impact on gesture accuracy

域类别	10 Epoch	50Epoch	100Epoch	150Epoch
源域	0.883 1	0.987 8	—	—
单源域迁移学习	0.277 3	0.592	0.586 3	0.562
多源迁移学习	0.447 1	0.653 4	0.808 1	0.731 6

为了验证本文算法在跨用户之间手势识别的性能,表 2 中给出了使用不同领域算法对手势识别的准确率对比。引入两种比较方式:1)单源域最优方式:使用源域数据集其中一组源域数据进行迁移,遍历整个数据集,选取最优的实验结果最为单源域最优方式的结果。例如:目标用户为 S6,则比较 S1→S6, S2→S6, S3→S6, S4→S6, S5→S6 这 5 种单源域迁移方式,选取其中精度准确率最高的结果。2)源域组合方法:将所有非目标域的源域数据组合成一个数据集作为算法的源域。源域组合方法是单源域方法应用于多源域中最为直接的方法。例如:目标用户为 S6,则通过计算 (S1, S2, S3, S4, S5)→S6 的迁移精度作为最后结果。

依据上述比较方式,将本文提出的多源域迁移学习和目前常用的领域自适应方法进行比较,并使用 $F1$ -score 作为评估指标。 $F1$ -score 综合考虑了模型的精确率和召回率,是一个常用的评价指标,尤其适用于不平衡类

别的分类问题。精确率是指在所有被分类为正类别的样本中,真正为正类别的样本所占的比例。召回率是指在所有真正为正类别的样本中,被分类器正确预测为正类别的样本所占的比例。

$$F1\text{-score} = \frac{2 \times Precision \times Recall}{Precision + Recall}$$

(14)

如式 (14) 所示为 $F1$ -score 计算公式,其中 Precision 为精确率,Recall 为召回率,结果如表 2 所示。

表 2 不同领域自适应方法对比

Table 2 Comparing domain adaptation methods

比较方法	迁移方法	平均识别准确率	$F1$ -score
单源域	DDC	0.603 1	0.587 6
	DAN	0.617 1	0.603 3
	Deep CORAL	0.735 8	0.724 6
	DANN	0.686 6	0.672 6
	DSAN	0.611 7	0.599 2
	DDC	0.667 7	0.654 1
	DAN	0.675 4	0.661 6
源域组合	Deep CORAL	0.769 5	0.755 8
多源域迁移学习	DANN	0.741 1	0.757 9
	DSAN	0.653 2	0.641 6
	本文方法	0.808 1	0.795 8
	Côté-Allard 等 ^[22]	0.689 8	—
	Xu 等 ^[23]	0.694 7	—
	Yang 等 ^[24]	0.761 2	—

通过表 2 中不同方法对比的结果可以看出,对于同一目标域,使用多源域数据的模型效果优于单源域数据建立的模型效果,同时本文方法在 Ninapro DB5 数据集中平均识别准确率为 80.81%,比 Côté-Allard 等^[22] 的识别率高 11.83%,比 Xu 等^[23] 的结果高 11.34%,比 Yang 等^[24] 的结果高 4.69%。在 $F1$ -score 数据值上,本文方法为 0.795 8,相较于单源域与源域组合有所提高。该结果一方面证明采用多个源数据集能够对目标域的分类准确率有帮助;另一方面证明引入其他源数据集能够进一步改善单源域迁移学习方法。由表中结果可知,使用本文的多源域迁移学习方法优于单源域和多源域组合迁移的分类结果,进而证明使用多源域迁移学习方法能够融合多个数据集,提高更高的跨用户分类识别精度,而无需考虑采用某个数据源效果更好。

从结果可知,本文方法能够在跨用户的手势识别应用中获得更高的识别精度,优于其他自适应方法。

2.3 讨论

1) 模型性能分析

模型的训练速度和性能不仅受到模型网络结构层数的影响,也会受到 Batch 的取值大小影响。选取适合的 Batch 大小不仅能够加快模型的训练速度,同时还能实现网络性能的进一步提升。本文通过对不同的 Batch 值做

实验探究,其结果如表 3 所示。

表 3 不同 Batch Size 下对结果的影响

Table 3 The impact of different batch sizes on the results

Batch Size 大小	平均准确率	标准差	模型训练时间/s
64	0. 803 4	0. 92	2 477
128(本文)	0. 808 1	0. 65	2 429
256	0. 782 1	1. 34	2 317
512	0. 766 8	2. 22	1 910

从表 3 可以看出,本文选取的 Batch 大小为 128,能够有最高的识别准确率和最小的标准差,性能优于其他比较的 3 种方法。

2) 共有特征提取器方法比较

为选择最优共有特征提取器模块,本文选择了多种方法获取共有特征,包括 CNN、TCN、LDA-f 和 LSTM。如表 4 所示。

表 4 共有特征提取器

Table 4 Common feature extractor

共有特征提取器	准确率	训练时间/s
LDA-f	0. 637 1	1 698
TCN	0. 748 5	2 849
CNN	0. 762 3	2 731
LSTM	0. 808 1	2 429

本文完整模型使用 LSTM 共有特征提取器的准确率为 80. 81%,比使用 LDA-f、TCN 和 CNN 方法,准确率分别提高了 17. 1%、5. 96%和 4. 58%,可以看到使用 LSTM 方法能够有效提高模型识别准确率。同时,LSTM 的识别识别时间为 2 429 s 相较于 TCN 减少 420 s,相较于 CNN 减少 302 s,LSTM 在提升识别效率上更有优势。因此本文采用 LSTM 作为共有特征提取器提取数据特征。

3) 消融实验

为了验证本文方法中的每一个模块的影响,本文使用消融实验来研究各模块的性能,结果如表 5 所示。

表 5 消融实验

Table 5 The impact of different batch sizes on the results

迁移学习方法	准确率
完整模型	0. 808 1
移除 CORAL loss	0. 693 2
移除 disc loss	0. 781 1
移除 CORAL+disc loss	0. 637 8

本文所使用多源域迁移学习方法中的每种结构的有效性,完整模型与在移除 CORAL loss、移除 disc loss、移除 CORAL+disc loss 相比在目标域准确率提高 11. 49%、2. 70%、17. 03%,同时分类器对齐又具有计算量小的优势,因此对齐多个域分类器在领域自适应中具有很大的潜力。

3 结 论

本文针对跨用户手势识别中存在个体差异性问 题,提出了一种多源域迁移学习模型实现肌电-惯性特征融合,通过共有特征提取器与域特征提取器完成对多个源域的特征提取及特征融合,引入特有特征对齐及域分类对齐方法,减小源域与目标域特征偏移。通过与单源域最优和源域组合最优方法的对比分析,表明多源域迁移学习的手势识别精度有所提高。并通过参数影响因素分析及消融实验研究,结果表明当移除相应模块识别精度有所下降,验证了多源迁移学习模型的有效性与准确性。

参考文献

[1] 张娜,张明进,王晓冬,等. 基于表面肌电信号的手指关节角度估计方法[J]. 电子测量与仪器学报, 2023, 37(8): 60-70.
ZHANG N, ZHANG M J, WANG X D, et al. Finger joint angle estimation method based on surface electromyography signal [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(8): 60-70.
[2] NAM Y, KOO B, CICHOCKI A, et al. GOM-Face: GKP, EOG, and EMG-based multimodal interface with application to humanoid robot control [J]. IEEE Transactions on Biomedical Engineering, 2013, 61(2): 453-462.
[3] 李芳,郑洁皎. 手康复机器人治疗脑卒中后手功能障碍的研究进展[J]. 中华物理医学与康复杂志, 2016, 38(9): 709-712.
LI F, ZHENG J J. Research progress of hand rehabilitation robot in the treatment of hand dysfunction after stroke [J]. Chinese Journal of Physical Medicine and Rehabilitation, 2016, 38(9): 709-712.
[4] 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.
[5] QIU S, WANG H, LI J, et al. Towards warable-inertial-sensor-based gait posture evaluation for subjects with unbalanced gaits[J]. Sensors, 2020, 20(4): 1193-1208.
[6] 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 Z Y, ZHAO X G, ZHANG B, et al. Research progress of intention recognition method based on surface electromyography under non-ideal conditions [J]. Acta

- Automatica Sinica, 2021, 47(5): 955-969.
- [7] 赵世昊,周建华,伏云发. 注意力机制 CNN 结合肌电特征矩阵的手势识别研究[J]. 电子测量与仪器学报, 2023, 37(6): 59-67.
- ZHAO SH H, ZHOU J H, FU Y F. Research on hand gesture recognition based on attention mechanism CNN combined with EMG feature matrix [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(6): 59-67.
- [8] PATRICIA N, TOMMASIT T, CAPUTO B. Multi-source adaptive learning for fast control of prosthetics hand[C]. 2014 22nd International Conference on Pattern Recognition, 2014: 2769-2774.
- [9] AMERI A, AKHAEI M A, SCHEME E, et al. A deep transfer learning approach to reducing the effect of electrode shift in EMG pattern recognition-based control[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2019, 28(2): 370-379.
- [10] 胡学政,陶庆,赵暮超,等. 采用迁移学习的表面肌电信号手势识别方法[J]. 科学技术与工程, 2024, 24(12): 5044-5050.
- HU X ZH, TAO Q, ZHAO M CH, et al. SEMG gesture recognition method using transfer learning[J]. Science Technology and Engineering, 2024, 24(12): 5044-5050.
- [11] ISON M R, ARTEMIADIS P. Beyond user-specificity for emg decoding using multiresolution muscle synergy analysis[C]. Dynamic Systems and Control Conference. American Society of Mechanical Engineers, 2013, 56123: V001T08A006.
- [12] JIANG X, BARDIZBANIAN B, DAI C, et al. Data management for transfer learning approaches to elbow EMG-torque modeling [J]. IEEE Transactions on Biomedical Engineering, 2021, 68(8): 2592-2601.
- [13] 张小恒,李勇明,王品. 双阶段帕金森病语音聚类包络卷积稀疏迁移学习算法[J]. 仪器仪表学报, 2022, 43(11): 151-161.
- ZHANG X H, LI Y M, WANG P. Two-stage PD speech clustering envelope and convolution sparse transfer learning algorithm [J]. Chinese Journal of Scientific Instrument, 2022, 43(11): 151-161.
- [14] ZENG R, WEN Y, ZHAO W, et al. View planning in robot active vision: A survey of systems, algorithms, and applications[J]. Computational Visual Media, 2020, 6(3): 225-245.
- [15] PARAJULI N, SREENIVASAN N, BIFULCO P, et al. Real-time EMG based pattern recognition control for hand prostheses: A review on existing methods, challenges and future implementation[J]. Sensors, 2019, 19(20): 4596.
- [16] BASSANI G, FILIPPESCHI A, GRAZIANO A, et al. A wearable device to assist the evaluation of workers health based on inertial and sEMG signals [C]. 2021 29th Mediterranean Conference on Control and Automation (MED). IEEE, 2021: 669-674.
- [17] 赵泽明,盛鑫军,朱向阳. 一款模块化可拓展式高密度肌电采集系统的设计[J]. 机械设计与研究, 2020, 36(4): 38-41, 56.
- ZHAO Z M, SHENG X J, ZHU X Y. Design of a modular and scalable high-density EMG acquisition system[J]. Mechanical Design and Research, 2020, 36(4): 38-41, 56.
- [18] 邢旭严,郭欣,张燕. 基于正常人的肌电模式识别抗力变化的鲁棒性研究[J]. 中国康复医学杂志, 2020, 35(2): 195-199.
- XING X Y, GUO X, ZHANG Y. Research on robustness of resistance change based on EMG pattern recognition resistance in normal people [J]. Chinese Journal of Rehabilitation Medicine, 2020, 35(2): 195-199.
- [19] 李芳卓. 基于下肢肌电信号的跨个体步态识别研究[D]. 哈尔滨:哈尔滨工业大学, 2021.
- LI F ZH. Across individual gait recognition based on lower limb muscle electrical research [D]. Harbin: Harbin Institute of Technology, 2021.
- [20] CAMPBELL E, PHINYOMARK A, AL-TIMEMY A H, et al. Differences in EMG feature space between able-bodied and amputee subjects for myoelectric control[C]. 2019 9th International IEEE/EMBS Conference on Neural Engineering (NER), 2019: 33-36.
- [21] 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 neurorobotics, 2016, 10: 9.
- [22] CÔTÉ-ALLARD U, FALL C L, DROUIN A, et al. Deep learning for electromyographic hand gesture signal classification using transfer learning [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2019, 27(4): 760-771.
- [23] XU Z Y, YU J X, XIANG W T, et al. A novel SE-CNN attention architecture for sEMG-based hand gesture recognition [J]. CMES-Computer Modeling in Engineering & Sciences, 2023, 134(1): 157-177.
- [24] YANG J, MENG F, WU Y, et al. Gesture recognition of surface electromyography signal based on multi-source domain transfer learning [C]. 2023 5th International Conference on Frontiers Technology of Information and Computer (ICFTIC). IEEE, 2023: 245-248.

作者简介



E-mail: pingx@ysu.edu.cn

Xie Ping received her B. Sc. degree from Yan Shan University in 1993, M. Sc. degree from Yan Shan University in 1996 and Ph. D. degree from Yan Shan University in 2006, respectively. Now she is a professor in Yan Shan University. Her main research interests include multimodal biological signal processing and Brain computer interface and intelligent control, brain intelligence can be integrated.



Now he is a M. Sc. candidate in Yan Shan University. His main research interests include human-computer interaction, gesture recognition of surface electromyography.



Now she is a Ph. D. candidate in Beijing

谢平, 1993 年于燕山大学获得学士学位, 1996 年于燕山大学获得硕士学位, 2006 年于燕山大学获得博士学位, 现为燕山大学电气工程学院仪器科学与工程系教授, 主要研究方向为多模态生物信号处理、脑机接口及智能控制、脑机智能融合。

赵连洋, 2019 年于郑州大学获得学士学位, 2024 年于燕山大学获得硕士学位, 主要研究方向为人机交互、表面肌电手势识别。

E-mail: zhao_lianyang@163.com

Zhao Lianyang received his B. Sc. degree from Zheng Zhou University in 2019.

张艺滢, 2020 年于东华大学获得学士学位, 2023 年于美国萨凡纳艺术与设计学院获得硕士学位, 现为北京理工大学设计与艺术学院博士, 主要研究方向为面向医疗康复的多模态交互设计。

E-mail: zhangyiyang1998i@sina.com

Zhang Yiyang received her B. Sc. degree from Dong Hua University in 2020, M. Sc. degree from Savannah College of Art and Design in 2023. Now she is a Ph. D. candidate in Beijing

Institute of Technology. Her main research interest includes multimodal interaction design for medical rehabilitation.



徐猛, 2021 年于燕山大学获得学士学位。现为燕山大学电气工程学院研究生, 主要研究方向为人机交互、表面肌电手势识别。

E-mail: 529085456@qq.com

Xu Meng received his B. Sc. degree from Yan Shan University in 2021, M. Sc. degree from Yan Shan University in 2024. His main research interests include human-computer interaction, gesture recognition of surface electromyography.



江国乾, 2011 年于燕山大学获得学士学位, 2017 年于燕山大学获得博士学位。现为燕山大学电气工程学院自动化仪表系副教授, 主要研究方向为多模态人机智能交互、深度学习与智能系统应用。

E-mail: jiangguoqian@ysu.edu.cn

Jiang Guoqian received his B. Sc. degree from Yan Shan University in 2011, Ph. D. degree from Yan Shan University in 2017, respectively. Now he is a professor in Yan Shan University. His main research interests include Multimodal human-machine intelligent interaction and Deep learning and intelligent system applications.



陈杰(通信作者), 2012 年于沈阳体育学院获得学士学位, 2015 年于沈阳体育学院获得硕士学位。现为燕山大学体育学院教师, 主要研究方向为体育教学训练学。

E-mail: jiechen@ysu.edu.cn

Chen Jie (Corresponding author) received his B. Sc. degree from Shenyang Sport University in 2012, M. Sc. degree from Shenyang Sport University in 2015. Now he is a teacher in Yan Shan University. His main research interest includes physical education training science.