doi:10.3772/j.issn.1002-0470.2024.08.007

基于黎曼普鲁克的手部离散动作识别方法①

王志恒② 沈家和 都明宇 杨庆华③

(浙江工业大学特种装备制造与先进加工技术教育部/浙江省重点实验室 杭州 310023)(浙江工业大学机械工程学院 杭州 310023)

摘 要 肌电信号能反映人体的运动意图,是外骨骼和假肢控制的主要信号之一。但受 试者间的差异,增加了基于表面肌电信号(sEMG)的手部离散动作识别使用成本。针对 这一情况,本文从域适应的角度出发,提出一种基于小型调整集的迁移学习建模方法。该 方法利用黎曼普鲁克分析(RPA)提取黎曼特征与传统时域特征作为支持向量机(SVM) 的输入特征,并通过实验验证了其识别精度。在10名受试者身上进行了实验,在黎曼特 征下黎曼普鲁克分析相比于不进行迁移学习的动作识别方法提高了5%~7%的准确率。 在特征空间分布上,黎曼普鲁克分析后的黎曼特征的重合度更高。结果表明,该方法在基 于肌电信号的手部离散动作识别上有明显优势。

关键词 表面肌电信号(sEMG); 黎曼普鲁克分析(RPA); 手势识别; 支持向量机 (SVM); 迁移学习

由于易于检测和直观的特性,肌电信号(electromyography, EMG)是外骨骼和假肢控制中应用最 为广泛的信号[1]。肌电信号能反应骨骼肌在收缩 中的激活程度,包含神经系统信息,从而方便地从中 识别人体的运动意图[2]。并且,诸如线性判别分析 (linear discriminant analysis, LDA)^[3]、k 近邻、支持 向量机(support vector machine, SVM)^[4]等传统机器 学习与卷积神经网络(convolutional neural networks. CNN)^[5]、长短期记忆网络(long short-term memory, LSTM)^[6]、循环神经网络(recurrent neural network. RNN)^[7]等神经网络已被运用到手势识别中。先前 的研究大多侧重于在理想环境和无干扰环境下识别 更多的手势,但在实际应用中,肌肉收缩力^[8]、肢体 姿态^[9-10]、电极偏移^[11]、个体性差异、肌肉疲劳^[12]等 干扰因素会影响肌电信号的稳定性,从而降低手势 识别的准确率。

在先前的研究中,已有许多方法来增强手势识

别的鲁棒性。李愚等人^[13]使用基于 DBSCAN(density-based spatial clustering of applications with noise) 密度聚类的 SVM 增量学习算法对肌电信号进行增 量学习,加快了训练时间并提高了识别精度。Xu 等 人^[11]通过分析数据特征估计电极在手臂上的旋转 角度,再根据旋转角度对肌电信号进行旋转,实现原 始信号与目标信号的对齐,来削弱电极旋转对手势 识别的影响,准确率提高了30%。Ali等人[14]将时 域信号进行处理,提取了时变功率谱描述符特征,使 上肢残疾者在不同力度下的手势识别准确率提高了 6%~8%。Vidovic 等人^[15]提出了一种协变量移位方 法,通过调节提取特征的均值和方差来降低电极移 位的干扰,与未进行移位的结果相比,带协变量移位 的识别方法在测试不同时间采集的数据时,很好地 保持了识别准确率。Kanoga 等人^[16]使用竞争搜索 算法优化协变量移位的超参数,减少运算时间的同 时提高了识别准确率。Li 等人^[17]对 Alexnet 模型进

① 国家重点研发计划(2018 YFE0125600)和浙江省基础公益研究计划(LGG19E050023)资助项目。

② 男,1964年生,博士,副教授;研究方向:机器人运动控制,嵌入式系统开发及应用,信号处理;E-mail: wzh232@zjut.edu.cn。

③ 通信作者, E-mail: robot@ zjut. edu. cn。 (收稿日期:2023-02-06)

行迁移学习,在52个手势识别中,实现了70.4%的 准确率。但外界干扰对肌电的影响难以预测,并且 基于深度学习的迁移学习方法需要较高的计算成 本。通过较小的辅助数据集来对采集到的信号进行 处理,以减小训练集与测试集的特征分布的差异是 一种合适的迁移学习方法。

鉴于上述问题,本文提出一种将黎曼普鲁克分 析(Riemann Procrustes analysis,RPA)与黎曼切空间 投影^[18]相结合的迁移学习方法,通过黎曼普鲁克分 析进行特征变换,利用黎曼切空间投影完成特征从 黎曼空间至欧氏空间的投影。实验验证了黎曼普鲁 克分析能解决跨个体的手势识别效果不佳的困境, 验证了其对 SVM 分类器的优化效果,证明该方法在 肌电跨受试者手势识别领域有独特的优势。

1 手势识别方法

基于黎曼普鲁克的手部离散动作识别方法可以 分为预处理、特征提取、特征迁移、分类方法 4 个部 分。预处理通过活动段分割减少肌电信号的干扰; 特征提取对肌电信号进行降维与整理;特征迁移使 用黎曼普鲁克分析对不同受试者的肌电信号特征进 行特征变换;通过 SVM 对肌电信号进行分类识别。

1.1 活动段分割

对采集信号手势动作段的分割会影响分类器训 练的准确性。虽然进行实验时上位机程序提示被试 者在规定的时间内执行动作,但由于受试者的反应 时间、肌电信号的激活时间与程序手势提示时间不 完全重合,因此需要对手势进行准确的活动段划分, 即对肌肉激活段进行划分。在实验中,受试者的反 应时间小于1s,所以在预设活动段开始和结束处设 置长度为1000个采样点的检测窗口,允许受试者 以1s的延迟完成手势动作。在分割过程中本文使 用 Staude 和 Wolf^[19]提出的对数极大似然比算法进 行识别。先将检测窗口内各通道相加后取平均值得 到平均肌电信号 $\{y_1, y_2, y_3, \dots, y_{1000}\}$ 。令平均肌 电信号 $\{y_1, y_2, \dots, y_{1000}\}$ 的统计特性在 1 < t < 1000时发生了变化,且变化前的概率密度函数 $p_{\theta_0}y_i$ 和变化后的概率密度函数 $p_{\theta_0}y_i$ 不同。由于表面肌 电信号(surface electromyography,sEMG)统计学上相互独立,联合概率密度分布等于个体密度的乘积,则 肌肉激活状态在t时刻发生变化的概率 p_t 为

$$p_{\iota} = \prod_{k=1}^{\iota-1} p_{\theta_0}(y_k) \prod_{k=\iota}^{1000} p_{\theta_1}(y_k)$$
(1)

其中, *p*_{θ1} 和 *p*_{θ0} 代表肌肉激活状态下的概率密度函数和非激活状态下的概率密度函数; *θ*₁ 和 *θ*₀ 代表肌肉激活状态下的概率密度函数和非激活状态下的方差,由窗口外后 100 个采样点和前 100 个采样点的平均肌电信号计算得到。由于肌电信号符合零均值正态分布,所以其概率密度函数仅受其方差影响。

当 p_t 达到最大值,则当前时间点 $t = t_0$ 是肌电活动段起始点位。通过对式(1)除以 $\prod_{k=1}^{1000} p_{\theta_0}(y_k)$, 再取对数值可以得到 t_0 的表达式为

$$t_{0} = \arg \max_{1 \le t \le 1000} \sum_{k=t}^{1000} (\ln p_{\theta_{1}}(y_{k}) - \ln p_{\theta_{0}}(y_{k}))$$
(2)

1.2 特征提取

特征提取是提取表面肌电信号中关键信息、去 除冗余部分和干扰的重要方法。为了成功地对 sEMG 信号进行分类,将采集到的肌电信号通过滑 动窗口分割多个窗口 *S* 后提取黎曼特征与 Hudgins 特征集,其中 *S* = { $X_1, X_2, X_3, \dots, X_j, \dots$ }, X_j 为当前 窗口的肌电信号表达矩阵,表示为 X_j = { $x_{1j}, x_{2j}, x_{3j}, \dots, x_{ij}, \dots$ },其中 x_{ij} 代表第 *j* 组窗口内第 *i* 组肌电信 号。

1.2.1 Hudgins 特征集

传统的 Hudgins 特征集总共包含了 4 种时域特征,分别是平均绝对值、过零点个数、斜率符号变化和波形长度。平均绝对值(mean absolute value, MAV)特征与信号强度相关,是一段肌电信号幅度绝对值的平均值,其数学表达式为

$$MAV_{j} = \frac{1}{N} \sum_{i=1}^{N} |x_{ij}|$$
(3)

其中 N 为肌电窗口大小。

过零点个数 ZC 反应了肌电信号跨越零值的次数,为避免低电压波动或背景噪声,需要为其设定阈 值条件,其数学表达式为

$$ZC_{j} = \sum_{i=1}^{N-1} \left[u(-x_{ij} \cdot x_{(i+1)j}) \right]$$
- 855 -

$$u(x) = \begin{cases} 1 & x > 0 \\ 0 & x \le 0 \end{cases}$$
(4)

斜率符号变化值 SSC 描述了肌电信号正斜率 和负斜率之间的变化次数,通过阈值来减少噪声干 扰。在本研究中,选择了肌电信号峰值的 0.4% 作 为阈值。其数学表达式为

$$SSC_{j} = \sum_{i=2}^{N-1} f[(x_{ij} - x_{(i-1)j})(x_{ij} - x_{(i+1)j})]$$
$$f(x) = \begin{cases} 1 & x > \text{给定阈值} \\ 0 & \text{其他} \end{cases}$$
(5)

波形长度 WL 度量了肌电信号的复杂度,它被 定义为一个肌电信号在特定时间段的累加值,其数 学表达式为

$$WL_{j} = \sum_{i=1}^{N-1} |x_{(i+1)j} - x_{ij}|$$
(6)

1.2.2 黎曼特征

黎曼特征^[20]即协方差矩阵,最早被 Tuzel 等 人^[21]用来作为图像对象检测和纹理分类的方法。 近些年,协方差矩阵已被广泛应用于脑机接口分 类^[18]。第*j*组窗口的协方差矩阵 **P**_i 定义为

$$\boldsymbol{P}_{j} = \frac{\boldsymbol{X}_{j}\boldsymbol{X}_{j}^{\mathrm{T}}}{n-1} \tag{7}$$

其中n为采集时预先设定的通道数量。

求得的协方差矩阵满足对称正定的条件,因此 所有信号的协方差矩阵都处在一个黎曼流形中。此 时,常规的欧几里空间的方法无法适用于协方差矩 阵中。通常情况下需要用对数方法将其逆映射到切 空间即欧几里得空间中^[18],作为黎曼特征的特征向 量输入到分类器中进行分类,黎曼特征的特征向量 *G*;数学表达式如下。

 $G_{j} = \log(P_{j}) = P^{\frac{1}{2}}\log(P^{\frac{1}{2}}P_{j}P^{-\frac{1}{2}})P^{\frac{1}{2}}$ (8) 其中, P 为协方差矩阵的黎曼中心; P_j 是需要变换 的协方差矩阵,通过对数映射到黎曼中心处的切平 面上。

1.3 特征迁移

由于不同受试者的肌肉激活的不同,不同受试 者的数据集的概率分布存在差异,本文使用 RPA 来 减少2组数据集的概率分布差异。普鲁克分析是一 种统计形状分析方法,用于分析一组形状的分布情 况。通过对数据平移、旋转和缩放使2个数据集重 - 856 - 叠,以提高模型在新受试者的数据上的分类准确性。 与普鲁克分析类似,黎曼普鲁克分析同样使用平移、 旋转和缩放方法,使2个数据集重叠^[22]。不同的是 其将普鲁克分析应用到了黎曼空间中,因此原先的 欧氏距离替换为黎曼空间中的仿射不变距离。黎曼 普鲁克分析步骤如下。

第1步:平移。平移后的数据集的协方差矩阵 P' 黎曼均值等于单位矩阵 I,即:

$$\boldsymbol{P}_{i}^{r} = \boldsymbol{M} \times \boldsymbol{P}_{i} \times \boldsymbol{M}^{\mathrm{T}}$$

$$\tag{9}$$

$$\boldsymbol{I} = \boldsymbol{M} \times \bar{\boldsymbol{P}} \times \boldsymbol{M}^{\mathrm{T}} \tag{10}$$

其中,M为式(9)中的旋转矩阵, \bar{P} 为协方差矩阵的 黎曼均值。

第2步:缩放。根据原数据集在黎曼空间的分 布,缩放目标数据集:

$$\boldsymbol{P}_{j}^{s} = \left(\boldsymbol{P}_{j}^{r}\right)^{d} \tag{11}$$

$$d^{2} = \frac{\frac{1}{n_{s}} \sum_{j=1}^{n_{s}} \delta_{R}^{2}(\boldsymbol{P}_{j}^{r}, \boldsymbol{I})}{\frac{1}{n_{r}} \sum_{j=1}^{n_{T}} \delta_{R}^{2}(\boldsymbol{\tilde{P}}_{j}^{r}, \boldsymbol{I})}$$
(12)

其中, d 为缩放比例, P_j 为原受试者的协方差矩阵, \tilde{P}_j 为目标受试者的协方差矩阵, δ_R^2 为黎曼空间上的发射不变距离, n_s 和 n_T 为原受试者和目标受试者的协方差矩阵的数量。

第3步:旋转。使目标数据集与原数据集对应 点上的距离最小,旋转后目标受试者矩阵 \tilde{P}_{j}° 的公 式为

$$\widetilde{\boldsymbol{P}}_{j}^{o} = \boldsymbol{U} \; \widetilde{\boldsymbol{P}}_{j}^{s} \; \boldsymbol{U}^{\mathrm{T}}$$
(13)

$$\boldsymbol{U} = \arg \min_{\boldsymbol{U}^{\mathrm{T}}\boldsymbol{U}=I} \sum_{i=1}^{N_{l}} \delta_{R}^{2}(\boldsymbol{m}_{j}, \boldsymbol{U}\widetilde{\boldsymbol{m}}_{j}\boldsymbol{U}^{\mathrm{T}})$$
(14)

其中,U为式(13)中的旋转矩阵, $m_j \in R^{n \times n}$ 和 $\tilde{m}_j \in R^{n \times n}$ 为原受试者和目标受试者各个类的黎曼均值, N_i 为类的数量,在本文中为7。

完成上述工作后将黎曼普鲁克分析映射到欧式 空间中。令缩放比例 d = 1,则目标受试者变化后 协方差矩阵 \tilde{P}_{i}° 可写为

$$\widetilde{P}_{j}^{o} = U \times M \times \widetilde{P}_{j} \times M^{\mathrm{T}} \times U^{\mathrm{T}}
= \widetilde{Q} \times \widetilde{P}_{j} \times \widetilde{Q}^{\mathrm{T}}$$
(15)

将式(15)转置矩阵拆分,则得:

$$\widetilde{P_{j}^{o}} = \boldsymbol{Q} \times \widetilde{X_{j}} \times \widetilde{X_{j}}^{\mathrm{T}} \times \boldsymbol{Q}^{\mathrm{T}} = \widetilde{X_{j}^{o}} \times \widetilde{X_{j}}^{\mathrm{o} \mathrm{T}} (16)$$

其中, \widetilde{X}_{i} 为变化前目标受试者的肌电信号, $\widetilde{X}_{i}^{\circ}$ 为变化后的目标受试者的肌电信号。

同理,将原受试者经过平移的协方差矩阵 **P**_j, 可得:

 $P_{j}^{r} = \boldsymbol{M} \times \boldsymbol{X}_{j} \times \boldsymbol{X}_{j}^{T} \times \boldsymbol{M}^{T} = \boldsymbol{X}_{j}^{r} \times (\boldsymbol{X}_{j}^{r})^{T} \quad (17)$ 其中, \boldsymbol{X}_{j} 为变化前原受试者的肌电信号, \boldsymbol{X}_{j}^{r} 为变化 后的原受试者的肌电信号。

于是可以得到欧几里得空间上的黎曼普鲁克分 析变化公式:

$$\boldsymbol{X}_{i}^{r} = \boldsymbol{M} \times \boldsymbol{X}_{i} \tag{18}$$

 $\widetilde{X}_{j}^{o} = \boldsymbol{Q} \times \widetilde{X}_{j} \tag{19}$

1.4 分类器

本文使用 SVM 作为手势分类的分类器。其中 SVM 是常见的非线性分类器,它通过将样本上升到 高维,降低分类难度,通过超平面来对不同类别的样 本进行分类。SVM 是一类按监督学习方式对数据 进行二元分类的广义线性分类器,其决策边界是对 学习样本求解的最大边距超平面,可以将问题化为 一个求解凸二次规划的问题。与逻辑回归和神经网 络相比,SVM 在学习复杂的非线性方程时提供了一 种更为清晰、更加强大的方式。SVM 可以解决小样 本情况下的机器学习问题,简化了通常的分类和回 归等问题。由于采用核函数方法克服了维数灾难和 非线性可分的问题,所以向高维空间映射时没有增 加计算的复杂性。此外,SVM 算法利用松弛变量可 以允许一些点到分类平面的距离不满足原先要求, 从而避免这些点对模型学习的影响。

2 实验方案

2.1 实验对比方案

使用黎曼普鲁克分析进行迁移学习需要2个受 试者的肌电数据,并将其分为3部分。一名受试者 的肌电信号作为对照,选择其肌电信号作为训练集。 另一名受试者的肌电信号分为调整集、测试集2部 分。为比较黎曼普鲁克分析的有效性,本文设计了 以下实验方案来进行2种黎曼普鲁克分析,并与无 迁移学习方案进行了对比,其实验方案名称如表1 所示。

表1 实验方案介绍

方案名称	方案内容
H-ORG	不进行迁移学习,使用 Hudgins 特征集
R-ORG	不进行迁移学习,使用黎曼特征
R-RPA	使用黎曼普鲁克分析,并使用黎曼特征
H-RPA	使用欧几里得空间的黎曼普鲁克分析, 并对变换后的肌电信号提取 Hudgins 特征
Hudgins	同一受试者,使用 Hudgins 特征集
Riemann	同一受试者,使用黎曼特征

联合训练是一种常见的增量学习方法,它在全部已知数据上重新训练模型已达到增量学习上限,并且在迁移学习中常使用联合训练来提高识别准确率。进行联合训练时,将原训练集与调整集合并成为新的训练集进行训练。不进行联合训练时,则直接使用原训练集进行训练。在运用黎曼普鲁克分析时,默认加入了联合训练方案。为证明联合训练对肌电手势识别准确率的影响,在不同实验方案中对比了联合学习的有无对肌电手势识别准确率的影响,验证了联合学习在黎曼普鲁克分析中的重要性。

2.2 数据采集设备与肌群

实验中, 肌电信号采集设备使用傲意科技的 gForceOct 无线肌电仪, 肌电信号采样频率为1000 Hz, 使用 Qt 编译上位机系统如图1所示, 整体电信号采 集环境如图2所示。在实验中采集桡侧腕屈肌、指 浅屈肌、尺侧腕屈肌、尺侧腕伸肌、示指伸肌和桡 侧腕伸肌六通道肌电信号, 除了与手部动作相关性



图1 肌电信号采集界面



图 2 肌电信号采集环境

较小的肱桡肌,选择的肌肉基本囊括前臂的所有浅 层肌肉群。采集的肌群的位置如图 3 所示,肌电电 极放置位置如图 4 所示。



图4 肌电电极位置图

2.3 实验动作规范

实验参考 Ninapro 数据集^[23]的动作类型,从中 选取 7 种手势和手腕动作进行实验,具体形式如 图 5所示,其中编号 0 为放松(RE),编号 1 ~ 7 分别 为中等柱状抓握(MW)、指侧抓握(LT)、平行抓握 (PE)、四指抓取(TG)、球状抓握(PS)、两指捏取 (PP)、食指伸展(IF)。每种动作持续 20 s,在执行 过程中穿插 10 s 的放松时间,每组动作共采集 10 次,之后被试对象休息 5 min,继续进行下一种动作 的数据采集。本文被试对象共 10 人,其中 9 人为男 性,1 人为女性,年龄在 20 ~ 25 岁之间,均为右利手 且无任何肌肉神经疾病和残疾的健康人。为保证手 势标准性及执行时间尽可能相同,实验对象事先均 进行过一定练习。



2.4 实验流程

黎曼普鲁克的手部离散动作识别系统的流程如 下。首先,通过6通道肌电传感器采集手部动作表 面肌电信号。然后,使用极大似然法,微调手势开始 和结束时间。再后,滑窗并提取协方差矩阵作为肌 电信号的特征。原始数据集与少量目标数据集共同 组成测试集,在经过黎曼普鲁克分析后使其黎曼空 间差异最小化,并通过切空间投影或时域特征提取, 形成分类器的输入特征。训练集特征与训练集标签 作为输入,共同训练分类器。最后,根据剩余的测试 集优化模型,获得最优分类模型。

3 结果与分析

3.1 不同实验方案对肌电识别效果

原始肌电信号提取协方差矩阵后进行黎曼普鲁克分析,切空间投影或特征提取后输入 SVM 进行训练,不同方案在有无联合训练下的识别准确率如图 6所示。Hudgins 特征对同一受试者的识别准确率为 77.5%,黎曼特征对同一受试者的识别准确率为 79.9%。将黎曼特征与 Hudgins 特征相比,在同一受试者情况下,黎曼特征相比 Hudgins 特征集有更高的准确率。



R-RPA 进行联合训练后准确率达到了 68.0%, 比 R-ORG 方案高约 4.0%。R-RPA 无联合训练后 准确率达到了 68.0%,比 R-ORG 方案高约5.0%。 这说明黎曼普鲁克分析能大幅提升不同受试者间的 识别准确率,在有联合训练下结果更佳。

与不进行联合训练相比,进行联合训练所带来 的准确率提升是很可观的,最大达到40.0%。但不 进行联合训练的准确率较低,最高只有60.0%左 右。这也说明本文所使用的黎曼普鲁克分析不能使 用脱离调整集,每个新的受试者都需要重新扩充训 练集训练新的模型。

此外,通过计算不同受试者组合下肌电手势识 别的混淆矩阵来验证黎曼普鲁克分析的优化效果, 如图7(a)所示(横坐标的受试者作为训练集,纵坐 标的受试者作为测试集),在以受试者 A 为训练集、 受试者 B 为测试集组合下黎曼普鲁克准确率提高 最高,达到了15.1%;而在以受试者 I 为训练集、受 试者 J 为测试集组合下黎曼普鲁克准确率反而降低 了5.8%。造成以上差异的原因主要是因为每个个体 特征分布不同,生成的分类超平面也不同。虽然黎 曼普鲁克分析在部分受试者组合中不仅没有提升准 确率,相反还降低了准确率,但总体而言,曼普鲁克 准确率平均提高了 5.0% 的识别准确率,这说明黎 曼普鲁克分析对不同受试者组合下对肌电手势识别 仍有较好的效果。



通过计算不同受试者组合下肌电手势识别的混 淆矩阵来验证欧氏空间黎曼普鲁克分析的优化效 果,结果如图 8 所示(横坐标的受试者作为训练集, 纵坐标的受试者作为测试集),在以受试者 F 为训 练集、受试者 B 为测试集组合下黎曼普鲁克准确率 降低最小,为 14.9%;而在以受试者 G 为训练集、受 试者 A 为测试集组合下黎曼普鲁克准确率降低最 大,反而降低了 42.8%。造成以上差异的原因主要 是因为欧氏空间的黎曼普鲁克分析对手势识别准确 率基本没有影响,而使用 Hudgins 特征会降低手势 识别的准确率;欧氏空间黎曼普鲁克分析在部分受 试者组合中不仅没有提升准确率,相反还降低了准 确率,其准确率平均降低了 26.0%,这说明欧氏空 间的黎曼普鲁克分析对不同受试者组合下对肌电手 势识别效果较差。



图 8 欧几里得空间的黎曼普鲁克分析相对 Riemann 方案 所提升的准确率矩阵

3.2 调整集比例的影响

在肌电手势识别领域中,调整集大小通常为所 有数据的 10.0%。考虑到在联合训练中,调整集的 比例是影响迁移学习的准确率的主要因素之一,不 同比例的调整集会影响最终识别的准确率,以0.5% 的分类为步长,在不同实验验证方案中对比了不同 比例的肌电手势识别准确率,验证了调整集比例对 肌电手势识别的影响。不同方案下,调整集的比例 对肌电手势识别准确率的影响如图 9 所示。

由图 9 可知,所有使用联合学习方法的方案的 准确率都随着调整集所占比例的增加而增加,其中 增长最快的是带联合学习的 R-RPA 方案,随着调整 集比例从 1% 增加到 20%,其识别准确率增长了 40%。R-RPA 方案在调整集占比较小时,准确率增 长速度最快,增长速度随着占比的增加而减少,在 15% 左右趋于收敛。

对比带联合学习的 R-RPA 方案与 R-RPA 方 案,比带联合学习的 H-RPA 方案与 H-RPA 方案调 整集的有无对肌电手势识别影响显著,拥有调整集 的方案准确率能提升2%~40%。这说明在联合学



图 9 不同方案下调整集比例大小对准确率的影响

习中,调整集比例是影响识别准确率的主要条件之一。在所有调整集占比情况下,进行黎曼普鲁克分析迁移学习的方案的准确率总是大于未使用迁移学习的方案。通过统计学分析发现黎曼普鲁克分析过的准确率与原始数据具有统计学差异(p < 0.1),这一 860 —

证明了黎曼普鲁克分析确实提高了跨受试者的手势 分类准确率。

3.3 特征空间的比较

为分析黎曼普鲁克分析对特征空间的影响,本 文将特征向量投影至二维空间进行可视化。根据 3.2 节调整集比例对肌电手势识别的影响可以得 知,调整集增长速度在 15% 左右趋于收敛,考虑到 调整集的增加会增加计算成本并降低数据的泛用 性,最终选取了调整集比例为 15% 重新进行实验, 并对比了不同方案下的特征分布。在实验中所有方 案均使用联合学习,而且在进行特征空间比较时,训 练集均不包括调整集。

如图 10 所示,黎曼普鲁克分析后,训练集和测试集的特征分布重合度更高,而 Hudgins 特征虽然进行了变换导致特征值的大小发生变化,但在分布降低了特征空间重合度。





4 结论

本文针对肌电手势识别在跨受试者识别时会出 现准确率降低的问题,将黎曼普鲁克分析引入到肌 电手势识别中,并针对此进行了2种不同的特征提 取。对10名受试者在7种手势下进行实验,实验结 果表明,黎曼普鲁克分析能充分使用调整集的数据 对测试集数据进行平移、拉伸、旋转,增加训练集与 测试集的重叠度,最终实现在跨受试者情况下的准 确率的提升。与未进行迁移学习相比,黎曼特征提 升了5%~7%的识别准确率。但黎曼普鲁克分析 仅针对黎曼特征进行优化,并会降低 Hudgins 特征 的识别准确率。因此如若需要扩充特征向量,则需 要使用另外的迁移学习方法对扩充的特征进行变 换。未来的研究将会寻找其他更佳的特征组合与迁 移学习方法。

参考文献

- [1] ESPOSITO D, CENTRACCHIO J, ANDREOZZI E, et al. Biosignal-based human-machine interfaces for assistance and rehabilitation: a survey[J]. Sensors, 2021,21(20): 6863.
- [2] WEBSTER J G, CLARK J J W, NEUMAN M R, et al. Medical instrumentation application and design [M]. Hoboken: John Wiley & Sons, Inc, 1998:121-182.
- [3] LEONE F, GENTILE C, CIANCIO A L, et al. Simulta-— 861 —

neous sEMG classification of hand/wrist gestures and forces[J]. Frontiers in Neurorobotics, 2019,13(42):1-15.

- [4] 王亮,张安元,李佳佳,等.基于时频组合特征的 PSO-SVM 手势识别方法 [J].长春理工大学学报(自 然科学版),2021,44(4):104-110.
- [5] WEI W T, DAI Q F, WONG Y K, et al. Surface-electromyography-based gesture recognition by multi-view deep learning [J]. IEEE Transactions on Biomedical Engineering, 2019,66(10):2964-2973.
- [6] KIM J S, KIM M G, PAN S B. Two-step biometrics using electromyogram signal based on convolutional neural network-long short-term memory networks [J]. Applied Sciences, 2021,11(15):1-14.
- [7] HU Y, WONG Y K, WEI W T, et al. A novel attentionbased hybrid CNN-RNN architecture for sEMG-based gesture recognition [J]. Plos One, 2018,13(10):1-18.
- [8]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.
- [9] KANITZ G, CIPRIANI C, EDIN B B. Classification of transient myoelectric signals for the control of multi-grasp hand prostheses [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2018,26(9):1756-1764.
- [10] KHUSHABA R N, AL-TIMEMY A, KODAGODA S, et al. Combined influence of forearm orientation and muscular contraction on EMG pattern recognition [J]. Expert Systems with Applications, 2016,61:154-161.
- [11] XU Z J, SHEN L Y, QIAN J W, et al. Advanced hand gesture prediction robust to electrode shift with an arbitrary angle[J]. Sensors, 2020,20(4):1-14.
- TIAN J R, LI C C, LI C Q, et al. Improving wrist angle recognition accuracy under different load conditions [C] // The 9th Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER). Suzhou, China: IEEE, 2019:1267-1272.
- [13] 李愚, 柴国钟, 卢纯福, 等. 基于增量自适应学习的 在线肌电手势识别 [J]. 计算机科学, 2019,46(4): 274-279.
- [14] ALI T A H, KHUSHABA R N, BUGMANN G, et al.

Improving the performance against force variation of EMG controlled multifunctional upper-limb prostheses for transradial amputees [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2016,24(6):650-661.

- [15] VIDOVIC M M C, HWANG H J, AMSÜSS S, et al. Improving the robustness of myoelectric pattern recognition for upper limb prostheses by covariate shift adaptation
 [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2016,24(9):961-970.
- [16] KANOGA S, HOSHINO T, ASOH H. Subject-transfer framework with unlabeled data based on multiple distance measures for surface electromyogram pattern recognition [J]. Biomed Signal Process Control, 2022,74:1-9.
- [17] LI Y R, ZHANG W X, ZHANG Q, et al. Transfer learning-based muscle activity decoding scheme by low-frequency sEMG for wearable low-cost application [J]. IEEE Access, 2021,9:22804-22815.
- [18] BARACHANT A, BONNET S, CONGEDO M, et al. Multiclass brain-computer interface classification by riemannian geometry[J]. IEEE Transactions on Biomedical Engineering, 2012,59(4):920-928.
- [19] STAUDE G, WOLF W. Objective motor response onset detection in surface myoelectric signals[J]. Medical Engineering & Physics, 1999,21(6):449-467.
- [20] MANJUNATHA H, JUJJAVARAPU S S, ESFAHANI E T. Classification of motor control difficulty using EMG in physical human-robot interaction[C] // International Conference on Systems, Man, and Cybernetics (SMC). Toronto, Canada: IEEE, 2020:2708-2713.
- [21] TUZEL O, PORIKLI F, MEER P. Region covariance: a fast descriptor for detection and classification [C] // Computer Vision-ECCV 2006. Berlin, Germany: Springer, 2006:589-600.
- [22] YGER F, BERAR M, LOTTE F. Riemannian approaches in brain-computer interfaces: a review [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2017,25(10):1753-1762.
- [23] COGNOLATO M, GIJSBERTS A, GREGORI V, et al. Gaze, visual, myoelectric, and inertial data of grasps for intelligent prosthetics [J]. Scientific Data, 2020,7(1): 43.

Grasp motion pattern recognition on Riemann Procrustes analysis

WANG Zhiheng, SHEN Jiahe, DU Mingyu, YANG Qinghua

(Key Laboratory of Special Purpose Equipment and Advanced Processing Technology, Ministry of Education and Zhejiang Province, Zhejiang University of Technology, Hangzhou 310023)

(College of Mechanical Engineering, Zhejiang University of Technology, Hangzhou 310023)

Abstract

Electromyography (EMG) can reflect the movement intention of the human and it is one of the main signals for exoskeleton and prosthetic control. However, inter-subject variability increases the cost of using surface electromyography(sEMG)-based discrete hand motion recognition. In response to this situation, a transfer learning method is proposed based on small adjustment sets from the perspective of domain adaptation. This method utilizes Riemann Procrustes analysis (RPA) to extract Riemannian features and traditional time-domain features as the input features of support vector machine(SVM), and its recognition accuracy is verified by experiments. Experiments are carried out on ten subjects, and the Riemann-Plucker analysis under the Riemann feature increases the accuracy by 5% to 7%, compared with the action recognition method without transfer learning. In terms of feature space distribution, the overlap of Riemannian features after Riemann-Plucker analysis is higher. The results show that this method has obvious advantages in recognition of discrete hand movements based on EMG signals.

Key words: surface electromyography(sEMG), Riemann Procrustes analysis(RPA), pattern recognition, support vector machine(SVM), transfer learning