・康复工程・

基于正常人的肌电模式识别抗力变化的鲁棒性研究*

邢旭严1 郭 欣1.2 张 燕1

摘要

目的:在肌电模式识别的实际应用中,力的变化会影响训练分类器的性能,导致很差的鲁棒性。本文提出了联合频 域和谱域,提取四个频谱域特征进行分类来提高肌电模式识别分类器抗力变化的鲁棒性。

方法:本实验招募了7名健康受试者,对15个手部精细动作在三个不同力度水平下进行交叉验证分析。利用高密度 肌电信号提取频谱域四个与幅值无关的特征,以便提高肌电模式识别的鲁棒性,并与提取四个传统时域特征方法进 行对比研究。

结果:通过比较传统时域特征和频谱域特征之间的平均分类结果,频谱域特征显示出对抗力变化更好的鲁棒性。传统时域特征同力度水平间平均分类结果为89.31%±0.49%,不同力度水平间平均分类结果为76.57%±3.59%;频谱域特征同力度水平间平均分类结果为92.39%±0.26%,不同力度水平间平均分类结果为86.94%±2.23%。与传统时域特征相比,频谱域特征在同力度水平间平均分类结果增加了3.09%,在不同力度水平间平均分类结果增加了10.36%。特别当使用频谱域特征进行低强度测试时,分类器的平均分类结果为70.97%,比传统时域特征高20.45%。 结论:与传统时域特征方法相比,频谱域特征具有显著的比较性优势。提取频谱域特征可能成为一种运动意图识别的有效方法。

关键词 脑损伤;手部运动意图;鲁棒性;力水平变化;肌电模式识别
中图分类号:R651;R741.0,R496 文献标识码:B 文章编号:1001-1242(2020)-02-0195-05

脑损伤是一种常见的严重创伤性后遗症,患者急性期过 后常留有各种功能障碍^[1]。准确有效地判断患者的运动意 图,让其主动地投入到康复训练中,成为了主要的研究趋 势^[2]。肌电模式识别(electromyogram pattern recognition, EMG-PR)运动意图识别在很多实验室开展了相关研究^[3–5], 并且能达到一个较高的动作分类^[6–7]。然而实际工作中 EMG-PR方法仍存在许多不足^[8–9]。

大多数研究都集中评估患者运动意图性能,但患者执行 动作时,手臂运动中产生可重复和持续的肌电信号实际上是 不可能的。一般来说,基于EMG-PR的方法是通过恒定的力 度水平来执行运动训练的。例如,Tkach等^[10]证明了力变化 对传统的 TD(time-domain, TD)特征的分类性能有很大影 响。Amsuss等^[11]记录5位健康受试者的三个力量水平EMG 信号(最大自主收缩力的30%,60%和90%),结果表明分类 性能平均每天下降4.1%。Scheme等^[12]研究表明,如果力度 从20%变化到80%,分类错误将显著增加32%,甚至更高。 显然,力度变化是影响EMG-PR方法进行运动意图识别的一 个重要因素,亟需解决。 20世纪70年代初,"鲁棒性(Robustness)"开始用以表示 控制系统对特性或参数扰动的不敏感性。近年来,Scheme 等[12-14]研究表明使用经过不同力度水平的数据训练的分类 器可以提高分类性能。Tkach等[10]发现用低力度水平或联合 低和高力度水平训练分类器比只用高力度训练分类器时更 准确。基于EMG-PR的方法中,特征提取是必不可少的。本 研究提出一种联合频域和谱域提取特征值的方法,并将传统 时域特征与频谱域特征进行分类性能比较,以显示频谱域特 征良好抗力变化的鲁棒性。

1 实验方法

1.1 实验对象与实验系统简介

本研究招募了7名健康受试者(5名男性,2名女性,年龄 24—29岁,编号为S1—S7)参与实验。所有的受试者没有神经 疾病史和关节痛病史,并本着自愿的原则签署了知情同意书。

本研究采用的硬件系统是128通道的高密度EMG采集 设备(RAFA, TMSI, Holland),用来记录肌电图数据。所有 渠道的EMG信号经过截止频率为10Hz和500Hz的带通滤

DOI:10.3969/j.issn.1001-1242.2020.02.014

第一作者简介:邢旭严,女,硕士研究生;收稿日期:2018-07-13

^{*}基金项目:国家自然科学基金项目(61773151);河北省自然科学基金(F2018202279)

¹ 河北工业大学,300130; 2 通讯作者

波器,采样率为1024Hz。每个受试者共使用24个高密度表面EMG(HD-sEMG)电极,形成了8×3网格状,这些电极被均匀的放置在受试者的前臂上(图1)。





首先我们告知受试者实验分为三种不同力度等级,并要 求受试者自身感知执行力度等级且无力度反馈,以便模拟脑 损伤患者因肌张力与肌肉协同而不能准确执行所要求具体 力度大小的影响。所要求力度为:低等力度:大约为30%的 最大自主收缩力;中等力度:大约为50%的最大自主收缩力; 高等力度:大约80%的最大自主收缩力。每次试验前,试验 人员会简要地向受试者阐述实验动作的类型和具体的动作 要求(图2),让受试者每个动作重复1-2次,确保选取的试 验动作在受试者的能力范围内,并且熟悉整个试验的流程。 试验期间,所有受试者需要按照屏幕提示用主动手执行15 种特定动作(图2)。执行每个选定的运动时先用最小力度保 持4s,休息2s,中等力度保持4s,休息2s,高等力度保持4s,休 息10s,如此重复6次。为了避免肌肉疲劳,受试者可以在任 何情况下要求休息5min。

1.2 时域特征提取

提取的四个时域特征值分别为:平均绝对值(mean value),过零点数量(number of zero crossings, ZC),斜率符号变化次数(number of slop sign changes, SSC),脉宽(waveform length, WL)^[18]。这些特征值的特点是计算量较少,识别性能比较高,特征值从每一个分析窗中提取出来,代替原始信号表征特定的动作。

1.3 频谱域特征提取

目前,大多数肌电模式识别的研究都是基于恒力条件下



进行的。若将其直接推广到肌肉收缩力变化的情况,算法容易失去鲁棒性,实验结果受到影响,从而影响肌电模式识别控制的推广应用。这是因为基于模式识别的肌电控制一般都是采用肌电幅值相关的统计特征,这些特征会由于肌肉收缩力变化而发生改变。

针对以上问题我们联合频域与谱域提取了四个优化特征,发现4阶自回归参数模型系数第二分量(autoregressive, AR₂)、一阶谱矩(1st spectral moments,SM₁)、方差中心频率(variance of central frequency,VCF)及融合三阶谱矩(1st, 2nd and 3rd spectral moments,FSM)特征这4个与幅值无关的频谱域特征对肌肉收缩力不敏感。

自回归(AR)模型是一种预测模型,其将sEMG信号的 每个样本描述为先前样本xi-p加白噪声误差项wi的线性组 合。在EMG信号的分类中,AR模型ap的系数已被用作特 征向量。该模型基本上表现为以下形式:

 $x_i = \sum_{p=1}^{p} a_p x_{i-p} + w_i$ (p是AR模型的阶数) 谱矩是一种从肌电图功率谱中提取特征的统计分析方 法。前三阶谱矩(SM1,SM2,SM3)是最重要的谱矩,计算公 式如下:

$$SM_1 = \sum_{j=1}^{M} P_j f_j$$
$$SM_2 = \sum_{j=1}^{M} P_j f_j^2$$
$$SM_3 = \sum_{j=1}^{M} P_j f_j^3$$

方差中心频率VCF是功率谱密度重要的一个特征,它 是由谱矩进行定义:

$$VCF = \frac{1}{SM_1} = \sum_{j=j0+n}^{j0+n} P_j (f_j - f_c)^2$$

以及通过融合三阶谱矩特征定义为FSM(Feature Spectral Moments),计算公式如下:

$$FSM = \frac{SM_3}{(\log(SM_2 - SM_1) * \log(SM_3 - SM_2))}$$

1.4 数据分类

数据使用 MATLAB 软件(Mathworks, USA)进行离线 sEMG信号分析。首先利用巴特沃斯滤波器进行滤波,去除 工频干扰。再采用分析窗长为150ms,时间增量为50ms进

一行特征值的提取。对于sEMG信号用K折
交叉验证,随机把sEMG信号分为训练集
和测试集。本实验中高密度sEMG信号的
采样率为1024Hz,训练集数据与测试集数
据分为两种:同一水平力度进行训练和测试,分为低-低,中-中,高-高;不同水平力度
进行训练和测试,分为低-中,低-高,中-低,
中-高,高-低,高-中。

196 www.rehabi.com.cn

本研究利用线性判别分析(linear discriminant analysis, LDA)方法建立识别器,线性判别方法是常用模式识别方法, 在人脸识别和机器学习等领域中有广泛的应用。将训练集 特征向量矩阵结合线性判别分析的模式识别算法建立识别 器,而测试集样本用于进行离线分析。

1.5 统计学分析

实验中运用了两种不同的信号的模式识别方法进行运动意图识别,为了更科学的比较两种方法的效果,选择运用了 Matlab 中的 *t* 检验的统计学方法进行分析,显著性系数选择均为*P*=0.05。

2 结果

2.1 时域特征结果分析

图3显示了三种力水平下某个动作的sEMG信号,信号 振幅在不同的力水平之间有显著的变化。传统时域特征在 同一力水平的平均分类结果为89.31%,在不同力水平间的 分类结果仅为76.57%(图4)。



2.2 传统时域特征与频谱域特征结果比较

首先为了获得准确的肌电信息,对某位受试者所有通道 短时肌电信号的四个频谱域特征进行样条插值,绘制肌肉电 势图来表征前臂的肌肉放电情况。该平面图可以看作沿第 一列电极剪开后平铺的结果。分别以手掌开和手握拳两种 动作为例,结果如图5所示。在三种不同力度水平下频谱域 特征可以缩小同一动作不同力度之间的差异,直观的可以看 到三种不同力度水平的肌肉电势图相差无几,该结果证明了 频谱域特征的可行性。

其次对7名受试者同一力水平的传统时域特征与频谱





域特征的平均分类结果进行比较。传统时域特征的平均分 类结果为89.31%±0.49%,频谱域特征的平均分类结果为 92.39%±0.26%。并且经t检验分析发现传统时域特征与频 谱域特征差异有显著性意义,这可以看出提取与幅值无关的 频谱域特征更适合手部精细运动的离线运动意图识别。

表1和表2分别是不同力水平下传统时域特征和频谱域 特征的平均分类结果。九宫格对角线为同一力水平平均分 类结果,非对角线为不同力水平平均分类结果。从整体来

> 看,同一力水平分类结果总是比不同力水 平分类结果要高。并且力度较低的数据 做训练集的分类更优。不同力水平的时 域特征平均分类结果为76.57%±3.59%, 频谱域特征的平均分类结果为86.94%± 2.23%。从6种不同力水平的分类结果可 以看出,频谱域特征总是比时域特征的平 均分类结果高,大约3%到20%不等。

2.3 频谱域特征结果分析

为了更清晰的分析频谱域特征不同力度间动作分类的 差异性,将7名受试者的平均分类结果进行统计,结果见图6 (L代表低力度水平,M代表中力度水平,H代表高力度水 平)。从整体结果看,不同力度间进行分类,每位受试者中力 度做训练集和高力度做测试集时平均分类结果最高,为 91.99%。高力度做训练集和低力度做测试集时平均分类结 果最低,为69.44%。从各自结果看,两种力度水平交叉分类 时,较低力度水平做训练集结果更好(如M-H,L-M,L-H比 H-M,M-L,H-L结果更优)。相差较多的力度水平进行交叉 分类,结果较差(如L-H,H-L)。

进一步分析提取频谱域特征的同力度水平下十五类动 作分类情况,将平均混合矩阵结果进行研究(如图7),其中每 一列的和应为100%,对角线所示为每一类动作被正确识别 的准确率,同一列其他值则为被错误识别成其他动作的准确 率。从图中不难发现每一类动作的分类结果均在90%以上, 只有个别动作低于90%。从低力度等级水平可以看出,腕内 屈分类仅73.08%,主要识别为放松状态。可能是因为进行 低力度水平采集时,用力过小,导致识别为放松状态。从中

时域	训练-低	训练-中	训练-高
测试-低	89.31	77.75	50.51
测试-中	87.11	89.03	75.43
测试-高	79.41	89.23	89.57

表1 传统时域特征平均分类结果

表2 频谱域结合特征平均分类结果

频谱域	训练-低	训练-中	训练-高
测试-低	92.61	83.53	70.97
测试-中	90.45	91.62	84.35
测试-高	85.44	90.82	93.66





力度等级水平可以看出,分类低的动作与误识别动作有一定的相似性,所以识别错误的可能性很大。从高力度等级混合矩阵可以看出每类动作分类均很好,说明高力度等级数据对于不同类别的动作更容易进行分类处理。

3 讨论

准确预测脑损伤患者运动意图可以激发患者参与康复的积极性,有望促进脑功能重塑,提高康复训练效果,对手部精细运动功能的恢复具有重要的研究意义。本文对7名健康的受试者的15类动作通过比较传统时域特征和频谱域特征,频谱域特征显示出对抗力变化更好的鲁棒性。传统时域特征同力水平间平均分类结果为89.31%±0.49%,不同力水平间平均分类结果为92.39%±0.26%,不同力水平间平均分类结果为96.94%±2.23%。频谱域特征与传统时域特征相比,同力水平间平均分类结果增加了3.09%,不同力水平间增加了10.36%,差异有显著性意义(P<0.05)。我们进一步对受试者前臂肌肉放电情况进行了分析,发现频谱域特征在三种不同力水平下的电势图相差无几。这说明提取频谱域特征进行模式识别分类用于手指精细运动功能的主动神经康复训练是可行的。

本研究发现提取频谱域特征显著优于提取传统时域特 征进行分类,是因为手臂上采集的表面EMG信号振幅在不 同的力度水平之间有显著的变化。对于传统时域特征(如 MAV)都会受到sEMG信号振幅的影响,以至于进行模式识 别分类时会有较差的鲁棒性^[19]。而提取频谱域特征均与

198 www.rehabi.com.cn

图7 提取频谱域特征的平均混合矩阵



_	1	٦	7	1	1	-	0	1	-3-	-	-	-	A	1
93.27	0	0	2.88	1.92	0	0	0	0.96	0	0	0	0.96	0	0
3.76	90.23	0	0.75	3.01	0	0	0	0.75	0	1.50	0	0	0	0
0.78	0	91.47	1.55	3.10	0	0	0	0	0	0	3.10	0	0	0
0	0	0	91.53	0	0.85	0	0	0.85	0	1.69	0	0	0	5.08
17.52	0	0	0	78.83	0	0	0	0.73	0	0.73	2.19	0	0	0
0	0.93	0.93	1.85	0	94.44	0	0	0	0	0	1.85	0	0	0
0	0	0	0	0	0	94.26	0.82	0	0	4.10	0.82	0	0	0
0.83	0	0	0	0	0	3.31	91.74	0	0	0.83	3.31	0	0	0
0.70	0	0	1.41	0	0	0	0	93.66	0	2.82	0	0	0	1.41
0.85	0	0	2.54	0	0	0	0	1.69	88.98	5.08	0	0	0	0.85
0	0	0	0	0	0	0	0	0	0	89.38	0.88	0	0	9,73
0	0	0	0	2.80	0	0	0	0.93	0	0	91.59	0	1.87	2.80
0	5.31	0	1.77	0	0	0	0	1.77	0	0	4.42	84.07	0	2.65
0	0	0	0	0	0	0	0	1.50	0	1.51	0	0	96.99	0
0	0	0	0	0	0	0	0	0	0.02	0.1	0	0	0	99.88

_	1	٦	7	1	1	-		-	3	-	-	-	-	1
93.86	0	0	1.75	1.75	0	0	0	1.75	0	0	0	0	0	0.88
5,30	87.12	0	0	1.52	0	0	0	5.30	0	0	0	0.76	0	0
0	0	96.26	0.93	0	0	0	0	0	0	0.93	1.87	0	0	0
0	0	0	94.02	0	1.71	0	0	0	0	0	0	0	0	4.27
7.63	0	0	0	85.59	0	0	0	5.08	0	0.85	0.85	0	0	0
0	0	0.80	0	0	94.40	0	0	0	0	0.80	4.00	0	0	0
0	0	0	0	0	0	95.83	0	0	0	3.33	0	0	0	0.83
0	0	0	0	0	0	1.47	91.18	0.74	0	2.21	1.47	1.47	0	1.47
0	0	0	0	0	1.56	0	0	97.66	0	0	0.78	0	0	0
0	0	0	1.63	0	0	0	0.81	2.44	90.24	3.25	0	0	0	1.63
0	0	0	0	0	0	0	0	0.78	0	95.35	0	0	0.78	3.10
0.86	0	0	0	0.86	0	0	0	0.86	0	0	95.69	0	0	1.72
0	0	0	0	0	0	0	0	1.60	0	0	0.80	93.60	0	4.00
0	0	0	0	0	0	0	0	0	0	0.85	0.85	0	97,46	0.85
0	0	0	0	0	0	0	0	0	0	0.15	0	0	0	99.85

sEMG信号振幅无关,可以较好抗力变化,对力度水平不敏感,有较好的鲁棒性。因此是一种较为理想的运动意图识别方法。

本研究对低、中、高三种不同力水平平均分类结果进行 频谱域特征的可行性分析。对于不同力水平间,无论中力度 做训练或测试,与低力度和高力度的分类结果均较好。然而 对于力度水平相差较大的等级(如低力度与高力度),结果与 中力度水平分类结果相比均较低。这可能是因为中力度水 平与其他两个水平力度更相近,进一步证明了肌电模式识别 依赖于恒力下鲁棒性更优。为了更清晰地分析频谱域特征 分类结果,本研究还提取了同力度水平的分类混合矩阵。从 三个力度水平的混合矩阵结果可以看出,大体动作的分类结 果都可以达到90%以上,分类结果从70%到90%不等。这可 能是因为手部精细动作较多,分类混淆可能性较大。而且实 验过程较长,EMG信号容易受到肌肉疲劳、电极位移,皮肤 阻抗等影响。肌电模式识别抗力鲁棒性研究中,对于手部精 细动作研究还较少(大多为4—5个动作)。本研究进一步强 调了手部精细动作研究的重要性。

本研究中联合频域和谱域提取了四个与幅值无关的特 征进行分类,结果与传统时域特征相比有显著的优势。然而 参与本研究的受试者均为健康人,在后续研究中,我们会招 募一些脑损伤患者对模式识别分类抗力变化研究进行调整, 并对其它频谱域特征进行研究,是否可以进一步提高分类结 果。另外,本文仅通过离线分析进行模式识别的抗力鲁棒性 研究,下一步研究工作中,我们将搭建实时测试,提取一些实 时指标进行更为全面的研究。考虑到模式识别抗力鲁棒性 会受到幅值有关的特征影响,后续研究将考虑是否频谱域结 合时域进行有效融合提取特征,以对脑损伤模式识别抗力鲁 棒性进行深入研究。

参考文献

- Sung L, Dong-Wha K. Stroke connectome and its implications for cognitive and behavioral sequela of stroke[J]. Journal of Stroke, 2015, 17(3):256-267.
- [2] Kober SE, Schweiger D, Reichert JL, et al. Upper alpha based neurofeedback training in chronic stroke: brain plasticity processes and cognitive effects[J]. Applied Psychophysiology & Biofeedback, 2017, 42(1):69–83.
- [3] Hudgins B, Parker P, Scott RN. A new strategy for multifunction myoelectric control[J]. IEEE Trans Biomed Eng, 1993, 40(1):82–94.
- [4] Lu Z, Chen X, Zhang X, et al. Real-time control of an exoskeleton hand robot with myoelectric pattern recognition[J]. International Journal of Neural Systems, 2017, 27(5):1750009.
- [5] Geng Y, Ouyang Y, Samuel OW, et al. Identification of isotonic forearm motions using muscle synergies for brain injured patients[C]. International IEEE/EMBS Conference on

Neural Engineering. IEEE, 2017:633-636.

- [6] Li X, Chen S, Zhang H, et al. Towards reducing the impacts of unwanted movements on identification of motion intentions[J]. Journal of Electromyography & Kinesiology, 2016, 28:90–98.
- [7] Wei Y, Geng Y, Yu W, et al. Real-time classification of forearm movements based on high density surface electromyography[C]. IEEE International Conference on Real-Time Computing and Robotics. IEEE, 2017.
- [8] Pan L, Zhang D, Ning J, et al. Improving robustness against electrode shift of high density EMG for myoelectric control through common spatial patterns[J]. Journal of Neuroengineering & Rehabilitation, 2015, 12(1):110.
- [9] Li X, Chen S, Zhang H, et al. Effects of non-training movements on the performance of motion classification in electromyography pattern recognition[C]. Engineering in Medicine & Biology Society. Conf Proc IEEE Eng Med Biol Soc, 2014:2569.
- [10] Tkach D,Huang H,Kuiken TA. Study of stability of time-domain features for electromyographic pattern recognition[J]. Journal of NeuroEngineering and Rehabilitation,2010,7(1):21.
- [11] Amsuss S, Paredes L P, Rudigkeit N, et al. Long term stability of surface EMG pattern classification for prosthetic control[C]. International Conference of the IEEE Engineering in Medicine & Biology Society. Conf Proc IEEE Eng Med Biol Soc, 2013:3622.
- [12] Scheme E, Englehart K. Electromyogram pattern recognition for control of powered upper-limb prostheses: state of the art and challenges for clinical use[J]. Journal of Rehabilitation Research & Development, 2011, 48(6):643-659.
- [13] Al-Timemy AH,Bugmann G,Escudero J,et al. A preliminary investigation of the effect of force variation for myoelectric control of hand prosthesis[C]. IEEE,2013:5758-5761.
- [14] Li X, Xu R, Samuel OW, et al. A new approach to mitigate the effect of force variation on pattern recognition for myoelectric control.[C]//IEEE, 2016:1684.
- [15] He J, Zhang D, Sheng X, et al. Invariant surface EMG feature against varying contraction level for myoelectric control based on muscle coordination[J]. IEEE, 2017, 19(3): 874-882.
- [16] Khushaba RN, 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(11):154–161.
- [17] Macisaac DT, Parker PA, Scott RN, et al. Influences of dynamic factors on myoelectric parameters.[J]. IEEE, 2001, 20 (6):82-89.
- [18] Samuel OW, Zhou H, Li X, et al. Pattern recognition of electromyography signals based on novel time domain features for amputees' limb motion classification[J]. Computers & Electrical Engineering, 2017, 2017:1—10.
- [19] 张神权.表面肌电模式识别的新控制策略研究[D].中国科学 技术大学, 2017.