

基于多通道 sEMG 小波包分解特征的人手动作模式识别方法

都明宇, 王志恒, 苗 一, 鲍官军, 高峰, 杨庆华, 张立彬

(浙江工业大学 机械工程学院, 杭州 310014)

摘要: 为了满足主动康复训练和人机交互等复杂应用场景对多样性的人手运动模式识别需求, 提出了一种基于多通道表面肌电信号 sEMG 小波包分解特征的人手动作模式识别方法; 通过实验对比分析, 确定了最佳采样布局方案, 通过采集前臂表面肌电信号, 设计了基于数字滤波器的肌电信号活动段自动标识算法, 能快速准确地完成样本动作标签的制作; 以原始肌电信号的小波包分解系数作为特征向量训练分类器; 通过对比不同隐含层节点数对分类器模式识别准确率的影响, 最终确定 BP 神经网络模式分类器的所有结构参数; 设计并训练完成了 BP 神经网络人手运动模式分类器; 对 9 种手部运动的平均识别率达到 93.6%, 计算时间小于 150 ms。

关键词: 表面肌电信号; 小波包分解; 动作标签; 神经网络; 模式识别

Hand Action Pattern Recognition Based on Multi-channel sEMG Wavelet Packet Decomposition Feature

Du Mingyu, Wang Zhiheng, Xun Yi, Bao Guanjun, Gao Feng, Yang Qinghua, Zhang Libin

(College of Mechanical Engineering, Zhejiang University of Technology, Hangzhou 310014, China)

Abstract: In order to meet the needs of complex application scenarios such as active rehabilitation training and human-computer interaction, a hand motion pattern recognition method based on multi-channel surface EMG signal (shorted as sEMG) wavelet packet decomposition is proposed. Through the comparison and analysis via experiments, the optimal sampling layout scheme is determined. The automatic identification algorithm of the active segment signal based on the digital filter is designed by collecting the sEMG signal of the forearm surface, and the production of the label can be completed quickly and accurately. The wavelet packet decomposition coefficient of the original sEMG signal is used as the feature vector training classifier. By comparing the influence of different hidden layer nodes on the accuracy of classifier pattern recognition, all the structural parameters of BP neural network model classifier are finally determined. The BP neural network for hand motion pattern classification was designed and trained. The average recognition rate of 9 kinds of hand movements was 93.6% and the calculation time was less than 150 ms.

Keywords: sEMG; wavelet packet decomposition; action label; neural network; pattern recognition

0 引言

表面肌电信号 (surface electromyographic signals, sEMG) 是肌肉收缩过程中, 大量运动单位动作电位 (motor unit action potential, MUAP) 经肌肉、皮下组织和皮肤的传导叠加, 最终反映在皮肤表面的综合电效应^[1]。sEMG 具有易于拾取且无创伤性的特点, 所以近年来被广泛研究用以评估肌肉的运动状态从而实现对人体主动运动过程的解析^[2]。相关研究应用除了在医疗康复训练方面取得的一些显著成果外^[3-4], 已逐渐发展到更广泛的手势识别和人机交互领域^[5-8]。基于 sEMG 的人手动作模式识别的主要工作就是研究从表面肌电信号中辨识手的动作模式, 即 sEMG 的特征提取与动作模式识别。Alan Smith 等提取手臂 4 通道 sEMG 信号的 AR 特征, 使用高斯分

类器识别 4 种手部动作, 准确率达到 90%^[9]。Pingao Mei 等人将时频特征与 Elman 神经网络相结合分析肌电信号, 对伸腕、屈腕、展拳、握拳 4 种动作进行分类, 平均识别准确率可达 92.5%^[10]。Al Omari 等人以小波系数能量为特征采用泛化回归神经网络 (GRNN) 进行手部多模式识别, 识别率达 94%^[11]。Futamat 等人利用 SVM 法对 4 通道表面肌电信号进行模式识别, 识别率达到了 95.59%^[12]。Naik 等使用 4 通道 sEMG 和孪生支持向量机方法成功对 7 种手势及腕部弯曲动作进行了分析, 得到了平均 84.83% 的分类敏感度^[13]。

准确性、多样性和实时性是实现康复训练和人机交互等复杂应用的必要条件。现有研究表明, 虽然目前基于 sEMG 的手部动作模式分类器对简单动作的识别率已经达到了比较高的水平, 但在识别多样性和实时性方面仍需改善。本文提出了基于多通道 sEMG 小波包分解特征的 BP 神经网络手指动作模式分类方法, 对包括手指动作、手势变化和腕部动作在内的 9 种手部动作 sEMG 进行小波包分解并提取特征, 通过实验方法对比不同隐含层 BP 神经网络分类器的性能, 确定了最优分类器结构。设计的分类器平均识别率可达 93.6%, 输出延时时间小于 150 ms, 能够满足手部运动康复、智能假肢等应用的实时性要求。

收稿日期: 2017-09-28; 修回日期: 2017-11-09。

基金项目: 国家自然科学基金项目 (51775499); 浙江省自然科学基金项目 (LQ15E050008); 浙江省教育厅科研项目 (Y201121563); 北京市智能机器人与系统高精尖创新中心开放基金项目 (2016IRS03)。

作者简介: 都明宇 (1977-), 男, 浙江舟山人, 博士研究生, 讲师, 主要从事机器人技术, 计算机控制技术, 模式识别与信息处理技术等方面研究。

1 前臂多通道 sEMG 信号采集

1.1 sEMG 采样系统

本文使用的 sEMG 信号采集仪具有 10 位 A/D 转换精度,采样频率 500 Hz,与上位机通过 USB 接口通讯,最大可以同时采集 12 路通道的 sEMG 信号。采样电极为自主设计可重复使用的 Cr17 材质无源表面干电极,每个采样通道使用 3 电极式差分输入,可以最大程度减少采样环节引入的共模干扰,保证采样信号的真实完整,采样设备如图 1 所示。




图1 sEMG 信号采集仪

由于待识别动作数量和电极位置组合形式多样,仅凭经验选择电极位置和采样通道数的常规方式并不严谨。为了降低主观因素干扰,本文使用信噪比作为评判衡量采样通道信号质量的客观标准。采样方案筛选阶段,逐一记录下预设的 47 个采样点在 9 种动作下的 sEMG 信号,计算各采样点原始 sEMG 的活动段信号能量与非活动段信号能量的比值作为该通道信噪比,选取信噪比综合排位最高的 5 个采样点构成最终的电极布局方案。对照人体前臂肌群解剖图,其中 4 个采样电极环形布置在前臂中段指总伸肌、尺侧腕伸肌、拇长展肌、尺侧腕屈肌、指深屈肌相关区域,另外 1 个采样电极布置于前臂中前段拇长屈肌位置。

1.2 sEMG 数据采样

为了保证手部动作的规范一致,受试实验人员都经过一定时间的练习。每种动作都以“放松”-“动作”-“放松”的形式循环进行,动作和放松时间都是 1~2 秒,每组测试持续 1 分钟时间,组间休息时间不小于 3 分钟。图 2 所示为“握拳”动作时的 5 通道 sEMG 原始信号。为了考察各采样通道信号频域细节,采用 welch 法估计各通道信号的功率谱密度。“握拳”动作 5 通道信号的功率谱密度如图 3 所示,其中实线为活动段 sEMG 信号功率谱,虚线为非活动段 sEMG 信号的功率谱。由活动段数据曲线可以看出 sEMG 信号的主要频率集中在 20~300 Hz 之间。由非活动段数据曲线可知,各类噪声干扰的频段分布比较均匀、能量较低。5 个通道的曲线有明显差异且排列有序,可以比较直观的反映采样通道的位置选择与动作的内在关联性。图形数据表明所采集的 sEMG 信号的总体质量良好,特异性比较明显,有利于后续特征提取和模式识别的顺利进行,也表明以信噪比筛选采样通道方案的设计合理性。

2 小波包分解特征提取与动作标签制作

2.1 小波包分解特征提取

sEMG 本质上是一种非平稳生物电信号。小波包变换是在小波分析理论上发展而来的信号分析方法,具有多尺度分析能力和良好的时频局部化特性,能够提供比小波变换更高的时频分辨率,非常适合分析非平稳信号的瞬态和时变特性。小波包变换包括小波包分解和小波包重构两个过程。




图2 原始 sEMG 信号 (握拳)




图3 sEMG 功率谱密度 (握拳)

小波包分解算法为:

$$\begin{cases} d_m^{j+1,2n} = \sum_l d_l^{j,2n} h_{l-2m} \\ d_m^{j+1,2n+1} = \sum_l d_l^{j,2n+1} g_{l-2m} \end{cases} \quad (1)$$

其中: h_{l-2m} 和 g_{l-2m} 是尺度 j 下的两组函数,通过分解算法可以使用尺度 j 下的系数 $d_l^{j,n}$ 计算下一尺度 $j+1$ 下的系数 $d_m^{j+1,2n}$ 和 $d_m^{j+1,2n+1}$ 。

小波包重构算法为:

$$d_l^{j,n} = \sum_m (d_m^{j+1,2n} h_{k-2m} + d_m^{j+1,2n+1} g_{k-2m}) \quad (2)$$

通过重构算法可以利用尺度 $j+1$ 下的系数 $d_m^{j+1,2n}$ 和 $d_m^{j+1,2n+1}$ 重构出尺度 j 下的系数 $d_l^{j,n}$ 。

原始肌电信号 $f(t)$ 经小波包分解后被投影到小波包基上,获得一系列系数 $d_l^{j,n}$,利用这些系数进行特征提取首先要确定使用的基函数类型。由于小波包分解包含众多的基函数,寻找最优小波包分解基就需要选择合适的代价函数 $M(x)$ 进行评估。本文使用香浓 (shannon) 熵作为代价函数,既定义序列 $x = \{x_j\}$ 的熵为:

$$M(x) = - \sum_j P_j \lg P_j \quad (3)$$

其中: $P_j = \frac{|x_j|}{\|x\|_2^2}$, 且 $P=0$ 时, $P \lg P=0$ 。通过使用代价函数对常用小波包基的评估,最终选择使用 db3 函数进行 2 层小波包分解提取特征向量。2 层小波包分解树如图 4 所示。




图4 2层小波包分解树

在经过 2 层小波包变换后,原始肌电信号 $f(t)$ 被分解成为 4 个不同频段分量,如图 5 所示,分解效果不仅可以反映原始信号的频域细节信息,而且通过分解系数重构的信号叠加后和原始信号保持一致,充分体现了分解系数对原始信号信息的还原能力。因此提取不同动作模式下肌电信号的小波包分解系数作为特征,可以为多样性模式辨识提供良好的条件。

为了便于提取蕴含在 sEMG 信号中的特征信息,本文对连续 sEMG 信号进行了分割处理,采用滑动窗口法将连续数据流分割成数据片段。对每个采样通道的每段数据应用 2 层小波包分解获得 4 个系数,再将 5 个采样通道的系数合并成为一条 120 的特征向量。为了保证特征向量的代表性和多样性,对每个动作截取连续的 10 000 条特征向量参与后续分类器的训

练和验证实验。




图 5 2 层小波包分解细节和信号的重构

2.2 sEMG 信号包络线提取

为了能够实现特征向量所属动作类型标签的自动添加，需将对应的原始信号划分为“活动段”和“放松段”。从图 2 可以看出，由于各通道 sEMG 信号波形具有动作同步性，本文提出了先将各通道信号进行绝对值求和处理，再经过低通滤波方式获取 sEMG 信号包络线的方法。该方法能够最大程度融合各通道的采样信息，保证对所有通道信号的包络效果。滤波器采用 3 阶切比雪夫滤波器。包络线的计算解析式为：

$$y(n) = \sum_{k=1}^a a_k y(n-k) + \sum_{k=0}^a b_k |x(n-k)| \quad (4)$$

其中： $x(n)$ 是原始信号， a_k 和 b_k 是滤波器参数。图 6 为经过延时修正的“三指对捏”原始信号包络曲线。可以看出该方法提取的包络线可以很好地贴合原始信号的轮廓，为后续制作动作标签提供了便利。




图 6 表面肌电信号包络线（三指对捏）

2.3 动作标签制作

从图 6 可以看到，表面肌电信号包络线的“峰”和“谷”对应的正是每个动作采样过程中的“动作”与“放松”。所以通过合理设置阈值即可将包络曲线转换成二值状态信号。如图 7-a 所示，传统的单一阈值法对状态转化的划分效果并不理想。由于信号在状态转换过渡区域必然存在较大波动，极易引起输出的反复越限，从而触发状态信号的错误翻转。为了解决这一问题，借鉴滞回比较器工作原理，采用双阈值法获取状态转换信号 $S(t)$ ：

$$S(t) = \begin{cases} 1 & y(t) > th_H \\ 0 & y(t) \leq th_L \end{cases} \quad (5)$$

阈值参数 $th_H > th_L$ ，在程序算法里对 $y(t)$ 的变化趋势进行跟踪，仅当数据上升过程穿越上限 th_H 或下降过

程穿越下限 th_L 才会触发状态信号翻转。如图 7-b 所示，通过合理设置两个阈值的数值，有效改善了状态信号翻转误触发情况的发生。




图 7 动作状态转换信号 $S(t)$

如表 1 所示，本文拟识别的 9 种手部动作包括“多指复合动作”、“手腕动作”和“放松动作”三类，其中多指复合动作又细分成“抓握动作”和“精准手势”两部分。

表 1 手部动作类型表

动作类型	动作描述	
多指复合动作	抓握动作	三指对捏(TH)
		钩形提取(HK)
	握拳	握拳(FT)
	食指“指示”	食指“指示”(IX)
腕部动作	精准手势	两指“胜利”(VC)
		三指“OK”(OK)
放松动作	屈腕	屈腕(WF)
	翻腕	翻腕(WE)
		自然松弛(RX)

如表 2 所示，为了便于计算机运算和识别，9 种动作被定义为 9 位二进制编码形式的动作标签。每种动作对应一个二进制制位，“1”代表有动作，“0”代表无动作。程序设计利用状态转换信号 $S(t)$ 对每种动作下的 10000 条特征向量自动添加所属动作类型的标签，从而完成所有参与分类器训练及测试数据的准备工作。

表 2 手部动作标签编码表

动作名称	标签编码									标签号
三指对捏	1	0	0	0	0	0	0	0	0	1
钩形抓取	0	1	0	0	0	0	0	0	0	2
握拳	0	0	1	0	0	0	0	0	0	3
食指“指示”	0	0	0	1	0	0	0	0	0	4
两指“胜利”	0	0	0	0	1	0	0	0	0	5
三指“OK”	0	0	0	0	0	1	0	0	0	6
屈腕	0	0	0	0	0	0	1	0	0	7
翻腕	0	0	0	0	0	0	0	1	0	8
自然松弛	0	0	0	0	0	0	0	0	1	9

3 实验与结果分析

3.1 BP 神经网络分类器设计、训练

人工神经网络作为一种对数据分布无特殊要求的非线性技术，能够有效解决非正态分布、非线性的评价问题。BP 神经网络作为人工神经网络中比较成熟一种网络模型，能够通过调整权重和阈值来“学习”或发现变量间的关系，实现对事物的分类，所以在模式识别、图像分析与处理、控制等领域都有着

表 3 17 个隐含节点的 BP 神经网络分类器输出混淆矩阵

手部动作		标签输出									实际输出 正确率/%
		TH	HK	FT	IX	VC	OK	WF	WE	RX	
实际输出	TH	1793	0	52	0	0	0	0	0	13	96.5
	HK	0	1592	66	93	0	0	2	0	66	87.5
	FT	0	0	1708	201	0	0	0	0	8	88.6
	IX	0	205	56	1375	0	0	0	0	14	83.3
	VC	0	0	0	0	1447	0	0	0	48	96.8
	OK	0	0	0	3	3	1877	6	0	16	98.5
	WF	0	0	0	0	0	6	1677	0	38	97.4
	WE	106	0	0	0	65	0	0	1917	47	89.8
	RX	42	111	96	76	241	60	13	176	15074	94.9
标签输出正确率/%		92.4	83.4	86.3	78.2	82.4	96.6	98.8	91.6	98.4	93.6

广泛的应用。

本文采用 3 层 BP 神经网络的分类器设计方案。每种动作使用 10 000 条特征向量参与分类器的训练与验证，训练与验证的样本不重叠，比例为 6：4。输入节点 20 个，输出节点 9 个。由于参与训练的样本数量较大且特征向量维数较高，为了加快收敛速度，提高训练效率，在对比不同算法的实际效果之后，确定采用量化共轭梯度算法进行分类器训练。训练结果的分类效果可以通过如表 3 所示的混淆矩阵定量显示出来。表 3 所示的是 17 个隐含节点的 BP 神经网络分类器的分类结果。混淆矩阵的每一行代表分类器对某一动作实际分类的正确与错误的样本分布，每一列代表原始标签样本被正确或错误分类的分布情况。例如，表 3 的第一行表示分类器将 1 793 个样本正确分入“三指对捏”模式，将 52 个“握拳”样本、13 个“松弛”样本错误分入“三指对捏”模式，分类器输出的准确率为 96.5%。第一列表示标准的“三指对捏”样本中有 1 793 个样本被成功分类，另有 106 个样本被分类器错分入“翻腕”模式，42 个样本被错分入“松弛”模式，标准“三指对捏”样本的分类准确率为 92.4%。

为了找到最佳的隐含层节点数的配置方案，实验共建立了 27 个分类器模型，分别针对 4—30 个隐含层节点的分类器进行训练。统计结果显示：1) 隐含层节点数的变化对分类器分类识别率的影响并不明显，也没有体现某种趋势或规律。2) 除了个别隐含层节点数太小训练失败以外，多数超过 10 个隐含节点的分类器的平均识别正确率维持在 90% 以上。当隐含节点为 17 时平均识别率达到了最高值 93.6%。3、9 种手部动作的单项识别率存在较明显差异。如表 3 所示，三指“OK”模式的识别率是 98.5%，单指“指示”模式的识别率仅有 83.3%。分析原因在于手部动作的可分性与动作的细节差异程度有关。在选择采样方案时更多考虑的是各通道对多种动作模式的综合信噪比，均衡评价的结果容易导致仅对个别动作贡献度较大的采样通道落选。因此对识别率明显过低的动作识别，可以考虑增加采样点补充信息或是提高对既有数据的特征提取细分程度。

本文采用的肌电信号采集仪信号转换及传输延时小于 2 ms；特征提取过程采用的是 64 个采样点的短窗，延时时间小于 ms，其中为采样周期。特征的提取算法简洁快速，单条特征向量提取耗时小于 20 ms，基于 BP 神经网络的分类器分类时间小于 5 μ s/次，所以从表面肌电信号采集到模式识别输出的总延时小于 150 ms。因此本文提出的方法可以满足主动康

复训练和普通人机交互控制领域的实时性要求。

4 结论

1) 提出一种以采样通道信噪比为评价标准的采样方案优选方法。依据多种动作模式下候选采样点 sEMG 信号的综合信噪比排序确定采样电极的位置和采样通道数，最终确定的 5 通道采样电极的布局方式在简化通道数的同时保证了高质量 sEMG 信号的拾取。

2) 提出一种检测多通道 sEMG 信号状态转换的快捷方法，不但能有效降低活动段检测错分率，而且能够自动依据状态转换信号完成对特征向量动作标签的添加，降低数据样本制作的时间和成本。

3) 设计了以 sEMG 信号小波包分解系数为特征，基于 BP 神经网络的手部动作多模式分类器。实验对比了多种训练算法和不同分类器结构对分类效果的影响，最终完成了对 9 种手部动作识别的分类器设计，平均识别率达 93.9%，延时小于 150 ms。

参考文献：

[1] DE Luca C J, Adam A, Wotiz R, et al. Decomposition of surface EMG signals [J]. Journal of neurophysiology, 2006, 96 (3): 1646–1657.

[2] Frigo C, Crenna P. Multichannel SEMG in clinical gait analysis: a review and state-of-the-art [J]. Clinical Biomechanics, 2009, 24 (3): 236–245.

[3] Sugar T G, Ping H J, Kleneman E J, et al. Design and control of RUPERT: a device for robotic upper extremity repetitive therapy [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2007, 15 (3): 336–346.

[4] Perry J C, Powell J M, Rosen J. Isotropy of an upper limb Exoskeleton and the kinematics and dynamics of the human arm [J]. Applied Bionics and Biomechanics, 2009, 6 (2): 175–191.

[5] Hargrove L J, Scheme E J, Englehart K B, et al. Multiple binary classifications via linear discriminant analysis for improved controllability of a powered prosthesis [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2010, 18 (1): 49–57.

[6] Ong SCW, Ranganath S. Automatic sign language analysis: A survey and the future beyond lexical meaning [J]. IEEE Transaction on Pattern Analysis and Machine Intelligence, 2005, 27 (6): 873–891.