

嵌入式人手姿态肌电模式在线识别方法

杨大鹏¹, 赵京东¹, 姜力¹, 刘宏^{1,2}

(1. 哈尔滨工业大学 机电工程学院, 哈尔滨 150001, law_1209@yahoo.com.cn;

2. 德国宇航中心 机器人及机电一体化研究所, 慕尼黑 82230)

摘要: 为了实现多自由度假手的肌电控制, 需要嵌入式地实现先进模式识别方法. 分别采用 K 近邻法及支持向量机分类方法, 在样本充足以及相对匮乏的情况下, 对实验中采集肌电信号的阈值特征集和稳态特征集进行了模式识别操作. 实验结果表明, 支持向量机的方法要明显优于近邻法, 采用阈值数据作为训练样本要比稳态数据实时识别效果好. 给出了一种在 DSP 内基于支持向量机进行 10 种人手姿态肌电模式的在线识别方法, 识别率在 95% 以上, 决策频率约为 30 Hz.

关键词: 肌电信号; 模式识别; 支持向量机

中图分类号: R318.04

文献标志码: A

文章编号: 0367-6234(2010)07-1060-06

Embedded online recognition of hand gesture EMG modes

YANG Da-peng¹, ZHAO Jing-dong¹, JIANG Li¹, LIU Hong^{1,2}

(1. School of Mechatronics Engineering, Harbin Institute of Technology, Harbin 150001, China, law_1209@yahoo.com.cn;

2. Institute of Robotics and Mechatronics, German Aerospace Center, Munich 82230, Germany)

Abstract: Controlling a multi-DOF prosthetic hand by EMG signals demands for effective pattern recognition methods that can be easily embedded in the controller of the hand. In this paper, methods of K-nearest neighbor and support vector machine (SVM) were used to identify different modes of myoelectric signals, which were obtained in several on-line experiments. Both methods were performed on different training sample sets, called threshold set and steady-state set, and in the case of abundance and relative insufficiency of samples. Experimental results show that the SVM method is superior to K-nearest neighbor, and the real-time recognition results are better when using threshold dataset as training samples than using steady-state dataset. The proposed method, which is based on SVM and embedded in DSP, can discriminate 10 hand gesture EMG modes with a prediction accuracy of above 95% and a decision frequency of about 30 Hz.

Key words: myoelectric signal; pattern recognition; support vector machine

肌电信号 EMG 是产生肌肉力的电信号根源, 在生物机理上是许多运动单元产生的动作电位序列的总和, 它是表示肌肉收缩信息的最直接、最简单的途径. 针对肌电信号的研究主要有肌病患^[1]、肌疲劳检测^[2]以及肌力估计^[3]等各个方面. 其中, 利用少数几个无创电极进行肌电信号检

测, 并结合模式识别理论进行人肢体不同肌肉动作模式的辨别有其重要的应用价值, 如进行灵巧手的遥操作^[4]、多自由度假手的感官控制^[5]等. 其中, 残疾人假手由于受到使用空间的局限性, 需要在单片机内部实现, 这就对模式识别算法有着更加苛刻的要求.

本文着眼于人手姿态模式的在线识别方法的片上实现, 详细讨论了近邻法以及支持向量机方法 (Support Vector Machine, SVM) 对不同尺度训练样本集的分类结果, 并给出一种基于 DSP (TMS320 F2812) 采用支持向量机进行人手姿态模式识别的在线方法.

收稿日期: 2009-02-16.

基金项目: 国家高技术研究发展计划资助项目 (2009AA043803);
国家自然科学基金资助项目 (60675045).

作者简介: 杨大鹏 (1982—), 男, 博士研究生;

刘宏 (1966—), 男, “长江学者”特聘教授.

1 方 法

文中采用两种不同的方法进行肌电信号模式的识别,一种是较易于实现的 K 近邻法,一种是基于统计学习理论的支持向量机方法. 其中,近邻法是一种非参数决策方法,其避开了概率的估计而进行直接决策,算法相对比较简单,易于实现. 设有 c 类样本,每类有样本 n_i 个, $i = 1, 2, 3, \dots, c$, 则近邻法则的判别函数为^[6]

$$g_i(X) = - \min \| X - X_{i,k} \| , k = 1, 2, \dots, n_i. \tag{1}$$

其中 X 为待分样本, $X_{i,k}$ 分别为各类近邻样本,决策法则为

若有 $g_i(X) > g_j(X), i \neq j, X$ 属于 i 类. $\tag{2}$

近邻法是一种次优方法,在实际应用中,数据样本往往是非常有限的,使其总体识别成功率不高. 即便是能获得相当大的样本,由于其在决策时需要计算待分样本同已知样本之间的距离,计算量巨大导致决策时间偏长,实时识别性能差. 因此,需要对于各模式内样本进行数量及质量上的规划,以便在成功率及决策速度上进行必要的取舍.

支持向量机则是一种高效可靠的分类工具^[7],其通过在两类数据之间布置一个超平面并使数据距离此超平面距离最大而对两类数据进行线性的分隔. 借助于“核”的概念,算法可以很容易实现非线性分隔,而计算量却没有明显增加. RBF 核与线性核的表达式为

$$K(x_i, x_j) = \exp(-\gamma \| x_i - x_j \|^2), \gamma > 0, \\ K(x_i, x_j) = x_i^T x_j. \tag{3}$$

其中: γ 为 RBF 核参数. 利用 Lagrange 优化算法可以将 SVM 二次规划问题转化为对偶问题求解,最终两类分类问题的决策函数为

$$f(x) = \text{sgn} \left[\sum_{i=1}^l \alpha_i y_i K(x_i, x) + b \right]. \tag{4}$$

式中: α_i 为拉格朗日乘子,上界为 C . 一般 α_i 不全为零,非零时对应的 x_i 即为此模式的支持向量. x, x_i 为待分及分类模式内全部特征向量. y_i 为样本对应的样本标号, -1 或 1 . b 为分类阈值.

参数 C 与 γ 需要预先给定,采用了以 2 为底的冥指数网格搜索的方法如令 C 分别等于 $2^{-3}, 2^{-2}, \dots, 2^6, \gamma$ 等于 $2^{-7}, 2^{-6}, \dots, 2^2$, 然后针对训练及验证成功率选取最优的搭配,本文通过实验最终确定 C 与 γ 的典型值分别为 32 与 $1/8$. 对于多类模式之间的识别,采用“One-Against-One”算法^[8].

2 实 验

本文实验涉及到肌电信号的采集,传感器使用 OttoBock 公司生产的表面肌肤电信号电极 13E125 = 50,其信号输出具备良好的时域特性,而频域特性较差,有用的肌电信息的频率范围处于 50 Hz 以下,因此采样频率选用 100 Hz,这与普通的差分放大电极普遍将采样频率设置为 1 000 Hz 不同. 而且,因为采样得到的多通道样本值可以直接作为分类用的特征向量,这将大量减少肌电信号后续处理(特征提取)的系统花费,提高在线识别的实时性. 肌电信号通过 DSP 目标板(基于 TI 公司 TMS320 F2812) AD 采集端口进入 PC 机(Matlab 同 CCS 接口 Link for Code Composer Studio),进行数据保存以供后续处理.

文中实验针对人手部 10 种不同的肌电信号模式,(图 1),分别为放松、拇指弯曲、拇指伸展、食指弯曲、食指伸展、三指(指中指、无名指及小指)弯曲、三指伸展、全弯、全伸以及捏取(拇指及食指). 实验采用 6 枚电极,分别位于 5 块前臂肌腹之上(图 2),具体各肌肉对应的基本模式见表 1. 特别地,食指以及三指弯曲皆选取了指浅屈肌,虽然是同一块肌肉,位置不同依然可以分辨食指以及三指的弯曲,三指伸展状态选择了小指固有伸肌.




图 1 10 种不同的人手姿态模式




图 2 肌电电极位置

表 1 肌肉名称及对应的基本模式

电极位置	肌肉名称	对应基本模式
1	拇短伸肌	拇指伸展
2	拇长屈肌	拇指弯曲
3	食指固有伸肌	食指伸展
4	指浅屈肌(食指)	食指弯曲
5	指总伸肌(小指固有伸肌)	三指伸展
6	指浅屈肌(三指)	三指弯曲

实验选取健康受试者 2 名(M,F),均无手臂神经肌肉病患史.实验在 5 个连续工作日进行 5 期,针对每一期具体实验,交替各姿态模式采集 5 组数据,每组各模式数据长度 5 s(500 点),组间间隔时间 20 min.采集时进行各模式“放松—收缩—持续—放松”动作,持续状态要占数据总长度 50% 以上.

每次采集得到各模式内数据长度为 500 点.将数据进行阈值处理,如果每一样本各通道内数据均无超越 0.5 V,即将此样本删去,得到阈值数据 A.将 A 中手部各模式收缩及放松开始时的样本删去,即在 A 中前后各截断一定长度 $L(L=25)$ 的数据,得到稳态数据 E.将 A 以及 E 中数据进行不同点数的求和平均,分别得到数据 B(10 点),C(50 点),D(100 点)以及 F(50 点),G(100 点),如图 3 所示.应该注意的是,手部放松模式按照上述操作均无阈值数据及稳态数据,因此不参与近

邻法及支持向量基的模式识别.它同其他模式之间的识别依靠简单的阈值决策,即依靠各通道样本值是否超越阈值 0.5 V.此阈值的选择使得各姿态模式发起时决策的延迟处于 100 ~ 120 ms,而且延迟终究不会造成实时识别手部动作的滞后感^[9].采用这种不同决策的手部姿态识别方法,对实时得到的特征识别的成功率较高,文中着重探讨除放松态以外的 9 种模式识别的问题,两类 SVM 分类器的数目为 C_9^2 个.




图 3 阈值特征集及稳态特征集

3 结 果

对于每个受试者,分别采用每期实验的前 3 次作为训练数据,后 2 次作为验证数据,总成功率取 5 期实验的平均值.识别方法分别采用 RBF 核、线型核 SVM 与最近邻、三近邻法.首先,针对样本较充裕的情况,分别进行阈值数据 A 及稳态数据 E 的成功率验证,如表 2 所示(前者为 M,后者为 F).其中 T 表示训练数据(前三次实验),P 表示验证数据(后两次实验),AT-AP 表示使用 A 中的训练数据进行训练,A 中的验证数据进行验证.相似的表示法还可见于 ET-EP,ET-AT,ET-AP 等.表 2 还给出了使用稳态数据 ET 进行训练,使用阈值数据 AP,BP 进行验证的成功率.

表 2 样本充裕情况下训练及验证成功率 %

识别方法		AT-AT	AT-AP	ET-ET	ET-EP	ET-AP	ET-BP
RBF SVM	M	98.91	96.94	100	99.90	94.23	94.93
	F	98.76	96.13	100	99.19	93.37	93.34
Linear SVM	M	98.32	96.38	100	99.90	94.39	94.93
	F	98.37	96.21	100	99.17	92.90	92.71
最近邻	M		95.90		97.95	92.07	92.83
	F		96.52		98.36	91.80	92.87
三近邻	M		95.91		98.20	92.17	92.83
	F		96.55		98.32	91.77	92.55

由表 2 可以看出,使用各组内的稳态数据,将得到较高的训练以及验证成功率. 特别是 $ET - ET$, SVM 方法的训练成功率均达到 100%,表明各模式内的稳态数据具有切实可分性. 而且,对于稳态验证数据 EP , 同样可以得到较高的验证成功率(SVM 的方法大于 99%,近邻法稍低,97% ~ 98%). 然而,当进行实时数据的验证时 ($ET - AP$), 成功率较低 (SVM:92% ~ 94%, 近邻法:91% ~ 92%), 这说明实时数据中具有一些暂态特征,这些特征致使分类器采用稳态数据进行训练时,实时识别将产生过多的错误,特别是在人手姿态模式发起之时. 相反地,采用阈值数据虽然在训练成功率上低于稳态数据,但是,在对实时数据(特指阈值数据 A , 其与实时数据采集中各模式特征集合比较接近)的识别中表现较好(SVM 方法大于 96%,近邻法 95% ~ 96%). 总体上,SVM 方法要优于近邻法,采用阈值数据作为训练(样本)特征要比稳态数据实时识别效果好,特别是使用近邻法时.

由于 A 以及 E 中的样本数目庞大(典型值, AT 样本数 >6 750, AE 样本数 > 4 050), 在 DSP 内部进行保存以及用于批量训练几乎是不可能的,因此研究了使用少数样本进行训练获得高成功率的可能性. 将 A 及 E 中的数据进行均值收缩,表 3 ~ 5 分别给出了采用收缩数据进行训练以及识别的结果.

表 3 收缩样本(10 点平均)训练及验证成功率 %

识别方法		$BT - BT$	$BT - BP$	$BT - AP$
RBF SVM	M	98.48	97.38	96.78
	F	98.97	96.67	95.91
Linear SVM	M	98.72	97.38	95.98
	F	98.74	96.36	95.72
最近邻	M		95.63	94.41
	F		96.83	95.89
三近邻	M		95.98	94.72
	F		96.04	94.95

表 4 收缩样本(50 点平均)训练及验证成功率 %

识别方法		$CT - CT$	$CT - CP$	$CT - AP$	$CT - BP$	$FT - AP$	$FT - BP$
RBF SVM	M	98.21	96.40	91.48	93.01	91.29	91.96
	F	100.00	96.75	94.38	95.09	90.68	91.44
Linear SVM	M	99.40	98.20	93.72	95.10	91.97	93.01
	F	100.00	99.19	94.68	95.09	90.85	91.44
最近邻	M		92.79	90.86	91.08	90.13	90.91
	F		95.12	92.74	92.55	90.59	91.28
三近邻	M		92.79	90.96	91.43	89.49	90.21
	F		96.75	92.78	93.34	90.26	90.65

表 5 收缩样本(100 点平均)训练及验证成功率 %

识别方法		$DT - DT$	$DT - DP$	$DT - AP$	$DT - BP$	$GT - AP$	$GT - BP$
RBF SVM	M	98.61	95.83	88.54	89.51	90.55	91.43
	F	100.00	100.00	92.43	93.19	89.61	90.17
Linear SVM	M	98.61	97.92	90.10	91.61	90.30	91.43
	F	100.00	100.00	92.60	93.19	89.45	90.17
最近邻	M		95.83	89.18	90.38	89.89	91.43
	F		100.00	91.45	91.28	88.81	89.06
三近邻	M		97.92	88.33	89.34	88.23	89.69
	F		100.00	90.67	91.76	85.00	86.05

如表 3 ~ 5 中所示,收缩后的阈值数据的训练及验证同样保持较高成功率,如 $BT - BT$ 、 $BT - BP$ 、 $CT - CT$ 、 $CT - CP$ 、 $DT - DT$ 、 $DT - DP$, Linear SVM 方法成功率最高(97% ~ 100%), RBF SVM 次之(95% ~ 100%), 近邻法最差(92% ~ 100%)。 $CT - CP$ 、 $DT - DP$ 的高成功率是建立在大窗口平均以获得稳定数据情况下, 它们的决策高频率虽然可以通过交叠窗口^[10]来实现,但是决策延迟必然很大,不适宜作为实时识别的特征。因此要考查使用 CT 、 DT 数据进行训练、实时在线采样信号 AP 作为验证特征时的成功率,见 $CT - AP$ 、 $DT - AP$ 。显然,它们低于使用全部阈值数据 AT 进行训练时的验证成功率($AT - AP$),更低于本身验证成功率($CT - CP$ 、 $DT - DP$),并且压缩越大,成功率越低(100 点收缩时出现低于 90%)。表中还给出了稳态数据收缩训练验证结果, FT 、 GT 比阈值数据 CT 、 DT 对实时特征的分辨更差,如近邻法的 $GT - AP$ 成功率全部低于 90%。从表中还可以看出,如果采用 10 点平均阈值数据 BP 进行验证,成功率将要比使用 AP 稍高,采用 Linear SVM 方法比 RBF SVM 方法成功率稍高。

表 6 计算量及占用存储比较

方法	训练样本数	支持向量数目	计算量(按乘法计,次)	占用存储/B
Linear SVM	857(81 88 85 111 93 95 103 89 112)	101(5 27 4 3 7 1 16 20 18)	5 656	4 588
近邻法			5 142	10 284

其中 Linear SVM 计算量的估算基于式(3)与式(4), $\alpha_i y_i$ 作为一个系数给出,而近邻法基于式(1)和(2)。对于占用存储的估算,由于近邻法需要保存全部样本数据进行距离的计算,因此需要全部保存,即占用 857×6 个 16 位数据空间(直接将 12 位 AD 采集值进行保存),而对于 Linear SVM 方法,如果采用片内训练则需要更多的数据位用于保存支持向量及对应系数,但是如果采用 DSP 同 PC 的数据交互,在 PC 机内部训练,则大大减少其所占的空间。训练采用 Matlab 环境下的 LibSVM^[11],训练完毕后得到各模式支持向量及对应系数值,将其通过头文件方式写入 CCS 工程文件中,共占用 $36 \times 1 \times 4 + 101 \times 6 \times 2 + 101 \times 8 \times 4 = 4\,588$ 字节的存储空间(式中 3 项分别为分类阈值、支持向量以及对应的系数值,分别按照长整型、整型、长整型进行保存)。为了提高决策速度,Linear SVM 与近邻法全部采用定点运算,样本值直接采用 DSP 的 AD 采样值(截断为 8 位),其

4 DSP 实现

实验结果表明,当使用充裕样本 AT 进行训练时,各种识别方法验证成功率并没有明显的差异。但是针对于片上训练、识别算法,往往受限于存储器大小以及芯片的计算速度。因此需要将训练样本进行压缩,以获得能代表各模式的特征样本,但这个过程时常是繁琐、耗时的。实验发现,直接采用不同点数的均值进行训练样本的压缩,在实时识别中仍旧可以保持良好的分类率,如对训练样本进行 50 点平均压缩,对 10 点平均压缩实时样本信号进行分类($CT - BP$),采用 Linear SVM 方法,可以获得 95% 以上的分类率。这时候总的训练样本 CT 为 135 ~ 270 个,即便采用近邻法(成功率只有 91% ~ 93%),对片上资源的消耗也是相对较少的。使用近邻法要想获得较高成功率,需要提供比数据 C 还要大的样本量,如采用数据 B (训练样本数为 675 ~ 1 350,成功率为 94% ~ 95%),其计算时间的消耗也将近似的增加 5 倍。表 6 显示了使用试者 M 数据 BT 作为训练样本,在 DSP 2812 内进行识别时,分别采用 Linear SVM 与近邻法的计算量以及所占用存储器大小。

中,经过 PC 机训练得到的 SVM 参数(系数 $\alpha_i y_i$, 分类阈值 b)需要进行放缩调整以适合定点整型相乘的运算,而决策函数式(4)则不需要修改。在线识别时,每一次决策输出后随即向 AD 采集索取一个样本,并立即进入模式分辨的计算,基于此配置的 SVM 识别决策频率一般处于 30 Hz 以上,且不需要扩展 DSP 的外部存储器。相似的 SVM 参数如果采用浮点保存及运算,决策频率将处于 3 Hz 左右,而且必须扩展存储器。

5 结 论

- 1)使用总体样本的阈值数据进行分类器的训练能提高其在实时识别中的成功率,且支持向量机的分类方法比近邻法普遍好。
- 2)在样本充分的情况下,虽然近邻法能获得较高分类率,但是计算量很大,难于在单片机内实现。
- 3)将训练样本进行均值收缩后,近邻法比支

持向量机分类成功率递减速度稍快,且对于实时样本(AP或者BP),小样本(100点均值收缩)近邻法成功率约为90%。

4)虽然使用大幅度均值样本(50点,100点)训练以及验证均能获得较高成功率,但是识别延迟大,实时性太差。因此,采用10点均值样本进行训练以及实时识别是较为合适的做法。

5)采用在PC机内进行SVM训练的方法,避免了在DSP片内进行训练样本的保存,节省空间,且避免了复杂的训练算法以节省存储空间。而且通过将识别算法由浮点运算转换为定点运算,决策速度提高近10倍,约为30 Hz。这种在线识别方法实时性好,算法准确率高,能较快跟随手部的动作模式。

6)基于此算法的肌电假手控制器最终应用于HIT/DLR Prosthetic Hand II,实现了多自由度假手的多模式肌电控制,且受试者普遍反应假手的控制灵活程度较高,“幻肢感”强烈。

参考文献:

- [1] BONATO P, SHERRILL D M, STANDAERT D G, *et al.* Data Mining Techniques to Detect Motor Fluctuations in Parkinson's Disease[C]//Proceedings of the 26th Annual International Conference of the IEEE EMBS. San Francisco, CA, USA: IEEE Press, 2004:4766-4769.
- [2] LARIVIERE C, GRAVEL D, ARSENAULT A B, *et al.* Muscle recovery from a short fatigue test and consequence on the reliability of EMG indices of fatigue[J]. European Journal of Applied Physiology, 2003, 89(2): 171-176.
- [3] MOBASSER F, HASHTRUDI-ZAAD K. Hand Force Estimation using Electromyography Signals[C]//Proceedings of the 2005 IEEE International Conference on Robotics and Automation. Barcelona, Spain: IEEE Press, 2005:2631-2636.
- [4] FARRY K A, WALKER I D, BARANIUK R G. Myoelectric teleoperation of a complex robotic hand[J]. IEEE Transaction on Robotics and Automation, 1996, 12(5):775-788.
- [5] BITZER S, VAN DER SMAGT P. Learning EMG control of a robotic hand: Towards active prostheses[C]//Proceedings 2006 International Conference on Robotics and Automation. Orlando, Florida, USA: IEEE Press, 2006:2819-2823.
- [6] 杨光正, 吴珉, 张晓莉. 模式识别[M]. 合肥: 中国科学技术大学出版社, 2001: 69-75.
- [7] CRISTIANINI N, SHAWE-TAYLOR J. An Introduction to Support Vector Machines[M]. Cambridge, England: Cambridge University Press, 2000.
- [8] KNERR S, PERSONNAZ L, DREYFUS G. Single-layer learning revisited: a stepwise procedure for building and training a neural network[M]. Berlin: Springer, 1990.
- [9] FARRELL T R, WEIR R F. The optimal controller delay for myoelectric prostheses[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2007, 15(1):111-118.
- [10] ENGLEHART K, HUDGINS B, PARKER P A. A wavelet-based continuous classification scheme for multi-function myoelectric control[J]. IEEE Transactions on Biomedical Engineering, 2001, 48(3): 302-311.
- [11] FAN R E, CHEN P H, LIN C J. Working set selection using the second order information for training SVM[J]. Journal of Machine Learning Research, 2005, 6:1889-1918.

(编辑 杨波)