

文章编号: 2095-0411 (2014) 01 - 0042 - 05

基于 SVM 的 4 类运动想象的脑电信号分类方法^{*}

庄 玮, 段锁林, 徐婷婷

(常州大学 机器人研究所, 江苏 常州 213164)

摘要: 针对传统支持向量机分类方法在脑电信号处理中存在分类正确率低的问题, 将聚类思想与二叉树支持向量机结合构造多类 SVM 分类器。实验以“BCI Competition 2005”中的 Dataset III a 为例, 先对采集的 4 类运动想象脑电信号应用小波变换进行去噪; 再在分析小波包频带划分特点的基础上, 利用小波包进行分解与重构, 获取相应的能量特征; 最后应用改进后的支持向量机 (SVM) 分类方法对特征信号进行分类。结果表明该方法分类正确率较高, 可以达到 91.12%, 并且有效的减少了分类器的个数, 最终达到较好的识别效果。

关键词: 脑机接口; 4 类运动想象; 特征提取; 聚类思想; 支持向量机

中图分类号: TP 242.6

文献标识码: A

doi: 10.3969/j.issn.2095-0411.2014.01.010

Research on Classification Method Based on SVM for the Four-Class Motor Imagery EEG

ZHUANG Wei, DUAN Suo-lin, XU Ting-ting

(Institute of Robotics, Changzhou University, Changzhou 213164, China)

Abstract: For the disadvantages of the traditional SVM classification in dealing with EEG signal, such as lower accuracy rate in classification, a multi-class SVM classifier is constructed by combining cluster idea with binary tree SVM. Based on data of the Dataset III a in the “BCI Competition 2005”. Firstly, four-class motor imagery EEG data collected is de-noised by the wavelet transform. Secondly, on the basis of analyzing the frequency band feature of wavelet packets, the corresponding energy feature is extracted by using decomposition and reconstruction of wavelet packets. Finally, the classification of the obtained feature signal is completed by using the improved SVM classification method. The simulation results show that the higher accuracy rate in the classification, about 91.12%, can be achieved. The number of classifier can be reduced efficiently and the relatively good identifying effects can be achieved finally.

Key words: brain-computer interface (BCI); four-class motor imagery; feature extraction; clustering idea; support vector machines (SVM)

脑机接口 (BCI) 是一种不依赖于大脑外围神经与肌肉正常输出通道的智能系统, 它真正实现了人脑与计算机或其它电子设备之间的直接的信息交

流和通讯控制^[1], 达到“人-机交互”的目的。而研究智能轮椅脑机接口系统可为思维正常但运动功能缺失的老年人或残障人, 特别是 ALS (amyo-

* 收稿日期: 2013-04-25

基金项目: 机器人技术与系统国家重点实验室开放基金重点项目 (SKLRS-2010-2D-09)

作者简介: 庄玮 (1988-), 女, 山东济南人, 硕士生; 通讯联系人: 段锁林。

trophic lateral sclerosis 肌萎缩性脊髓侧索硬化病) 患者提高自理能力提供新的对外信息交流渠道, 从而提高他们的自主能力和生活质量。基于运动想象脑电信号的智能轮椅脑机接口系统是当前的研究热点之一, 然而由于脑电信号的复杂性和非平稳性等特点^[2], 传统机器学习理论具有较大的局限性, 很难得到充足的特征数据对分类器进行训练并实现分类。

为更好地实现分类, 人们提出了统计学习理论, 它是针对小样本估计和预测的理论, 而支持向量机 (SVM) 分类方法是在 V. Vapnik^[3] 等人提出的统计学习理论的基础上发展起来的一种通用学习方法。最初是针对两类样本的分类问题, 目前许多研究者已将其推广到多分类问题, 并有一些较成熟的构造方案。本文应用基于聚类思想的二叉树支持向量机, 实现对 4 种不同运动想象脑电信号的分类, 得到了较高的分类正确率。

1 脑电信号的获取及预处理

本文采用的数据来自 2005 年国际 BCI 竞赛中的 Dataset IIIa 数据, 包含 4 类运动想象任务 (想象左手, 右手, 脚, 舌头), 数据由含 64 导的 Neuroscan 脑电放大器采集得到, 采样频率为 250 Hz, 并用带通滤波对数据进行了 1~50 Hz 滤波, 实验中采集的脑电数据为 60 个电极, 各电极摆放位置如图 1 所示。实验过程如图 2 所示。前

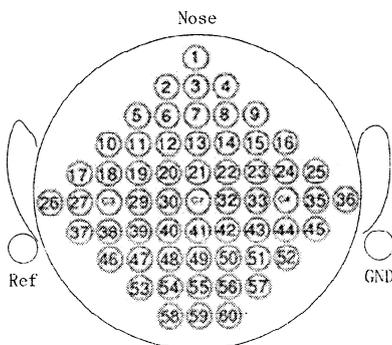


图 1 电极位置示意图

Fig. 1 Position of electrodes

2s 受试者处于安静状态, 在第 2s 时计算机发出提示音且屏幕出现“+”, 第 3s 时计算机屏幕随机出现向左、向右、向上或向下的箭头, 同时要求受试者按箭头方向分别进行左手、右手、舌头和脚的运动想象任务, 一直持续到第 7s, 有 3 名志愿者参与了试验 (分别标记为 K3b, K6b 和 L1b), 其中 K3b 执行 360 次试验, K6b 和 L1b 各执行 240 次

试验。先将采集到的脑电数据应用基于阈值的小波消噪方法进行预处理。

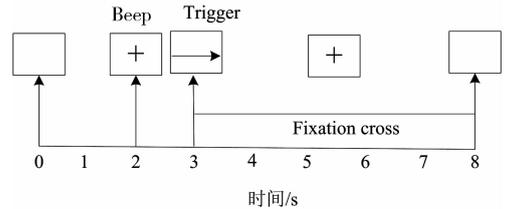


图 2 实验过程示意图

Fig. 2 Diagram of experimental process

2 ERD \ ERS 分析及特征提取

2.1 ERD \ ERS 分析

当人们想象单侧肢体运动时, 可以诱发大脑对侧感觉区的某些特征频段部分的能量发生强弱的变化, 这种能量减弱的现象称之为事件相关去同步 (event related desynchronization, ERD), 而能量增强的现象称之为事件相关同步 (event related synchronization, ERS), 为形象的表示这种变化, 可以以功率谱密度的值绘制相应的脑电地形图来进行对比。根据文献 [4] 研究表明: 由 4 类运动想象动作的脑电信号地形图对应的功率谱密度可以看出, 4 类想象动作的脑电信号的分布均具有相应的差异性; 且根据想象左手、右手和脚的动作表现出的事件相关去同步现象和想象舌的运动表现出的事件相关同步化现象, 想象左手、右手和脚的动作的事件相关去同步现象分别在 C4、C3 和 41 通道处最为明显, 而想象舌的运动的事件相关同步化现象在 24 通道处最为明显。因此本文选取 C3、Cz、C4、41、24 电极处记录的信号进行 4 类想象运动的特征提取与分类, 其中 Cz 作为参考电极。

2.2 脑电信号的特征提取

本文对预处理后的脑电数据采用小波包分析方法进行特征提取。小波包分析是一种非常有效的时频分析方法, 它能够为信号提供一种更加精细的分析方法, 在信号处理领域有着广泛的应用, 由于小波包分析不仅能将频带进行多层次划分, 还能对没有细分的高频部分进行进一步的分解, 因此对信号有一定的自适应性和更好的时频特性, 可提高脑电信号分析的精度^[5]。

由于支持向量机分类器对输入的向量的取值具有较严格的要求, 因此为了避免分类时取值范围大的属性比取值范围小的属性更占优势, 所以对所有

样本数据的各维进行了处理, 这样就将所有数据幅值线性调整到了 $[-1.5, +1.5]$ 之间。

3 脑电信号分类

3.1 支持向量机

支持向量机主要思想是通过某种事先选择的非线性映射 (核函数) 将线性不可分的空间映射到一个高维的线性可分的特征空间, 在这个空间利用结构风险最小化原则构造最优分类超平面, 使分类面两侧相距此平面最近的不同类样本之间间隔最大^[6], 对最优超平面的构造问题上可通过解决一个凸二次规划问题来实现: 即在约束条件 (1) 下, 使得函数 (2) 取得最小值。

$$y_i [\omega \cdot \Phi(x_i) + b] \geq 1 - \zeta_i, \zeta_i \geq 0, \quad i=1, 2 \dots l \quad (1)$$

$$\Phi(\omega) = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l \zeta_i \quad (2)$$

式中: x 为支持向量机的输入向量, y_i 为 x_i 所属类别, ω 为分类面的权系数向量, b 为分类域值, $C > 0$ 是惩罚因子, C 越大表示对错误分类的惩罚越大, ζ_i 为松弛因子。 Φ 将样本从输入空间映射到特征空间。上述优化问题可用其对偶规划进行求解:

$$\max_{\alpha} W(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (3)$$

s. t. $y^T \alpha = 0$

式中: $0 \leq \alpha_i \leq C, i=1 \dots l, 0 \leq \alpha_j \leq C, j=1 \dots l, i \neq j, K(x_i, x_j)$ 为核函数, $\alpha = [\alpha_1, \alpha_2 \dots \alpha_l]^T$ 为拉格朗日乘子, 若 $\alpha_i > 0$, 称相应的样本 x_i 为支持向量。应用标准的拉格朗日乘子法求解, 可得最终的分函数如式 (4) 所示:

$$y(x) = \text{sign}[\sum_{i=1}^l \alpha_i y_i K(x_i, x) - b] \quad (4)$$

但是, SVM 是普遍用于解决两类信号的分类, 要应用于多类信号问题, 需重新构造多类 SVM 分类器。目前, 对于多类分类问题, 一般有以下两种方法: ①在经典 SVM 理论的基础上, 直接在目标函数上进行优化, 重新构造多值分类模型。但是该算法目标函数十分复杂、且变量数目多^[7]; ②通过组合多个二类 SVM 分类器来实现多类问题的分类, 目前较常用的有一对多 (one - against - all, oaa) 和一对一 (one - against - one, oao) 两种算法^[2]。

以上两种构造方法都至少需要 $n-1$ 个 SVM, 因此计算复杂度非常高, 时间开销也比较大, 实现困难。所以本文针对以上算法的优缺点, 对四类运动想象脑电信号采用基于聚类思想的二叉树支持向量机进行分类。

3.2 基于聚类思想的二叉树支持向量机

针对传统的基于二叉树的支持向量机分类方法存在运算过程复杂、分类效率低等不足, 提出了一种基于聚类思想的支持向量机多类信号分类方法, 该方法在每个节点处, 按照某个分类测度选择出最易区分的类作为单独一类, 并与剩下的所有类构造分类面, 即每次分割出一类, 在分类过程中引入聚类思想, 把很有可能成为支持向量的样本选作训练样本来训练子分类器。再用得到的子分类器测试没有参与训练的其余样本, 检验是否存在违背子分类器最优化条件的样本, 如果有就将其加入到训练样本, 重新训练子分类器, 否则就进行下个子节点的子分类器的训练, 以此类推, 直到最后所有样本都能正确分类为止^[8], 基于聚类思想的二叉树分类方法如图 3 所示。

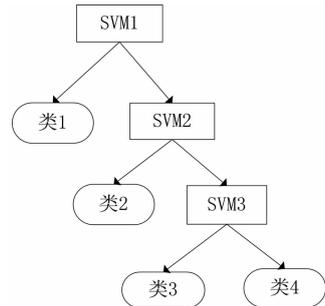


图 3 基于聚类思想的二叉树方法示意图
Fig. 3 BT - SVM based on clustering

3.2.1 隶属度分离测度

类间的分离测度量的是类与类之间的可分程度的大小, 表示类与类之间的远离程度。对 n 类问题, 一般定义为: $s_{ij} = d_{ij} / (\sigma_i + \sigma_j)$, 其中 d_{ij} ($i, j=1, 2 \dots n$) 为类 i 与类 j 中心间距离, σ_i 为类 i 的方差。那么类 i 的分离测度为: $s_i = \min_{j=1, 2 \dots n, j \neq i} (s_{ij})$, 而分离测度最大的类是最易分的类, 表示为 $s = \arg \max_{j=1, 2 \dots k} (s_j)$, $i=1, 2 \dots k$ 。但是当随机的测试样本 x 对所有类别的隶属度不同时, 也要考虑随机测试样本 x 对每个类别的隶属度^[9]。设 ρ_i 为随机测试样本 x 属于类 i 的概率, 那么类 i 的隶属度分离测度为 $s_i = \min_{j=1, 2 \dots k, j \neq i} (\rho_i s_{ij})$ 。

3.2.2 本文分类算法过程

①对 n 类样本 $x = \{x_1, x_2 \dots x_n\}$, 选择一类

样本 x_i ($i=1, 2\cdots n$), 计算该类样本与其他每个类 x_j ($j=1, 2\cdots n, j\neq i$) 的类间分离测度 s_{ij} 及对每个类别的隶属度 ρ_i ; ② 计算类 x_i ($i=1, 2\cdots n$) 的隶属度分离测度, 并从大到小进行排序, 选择其中最易分的类别; ③ 将最先分出的类 x_i 分割出来, 记为正类, 其余 $n-1$ 类记为负类, 对整个样本集采取无监督学习, 聚出几个子类 x_k ($k=1, 2\cdots n$); ④ 选择子类 x_k ($k=1, 2\cdots n$) 中既包含正类也包含负类的子类作为训练样本, 对其训练得到初始分类器 SVM; ⑤ 检查④中剩余的子类是否能够被正确分类, 能则转到⑥, 否则就将其添加到训练样本中, 继续训练 SVM, 直到所有样本能被正确分类; ⑥ 把类 x_i 从样本集中删除, 在第 2 个节点处, 选择 x_j 为正样本集, 其他样本为负样本集, 利用 SVM 算法构造最优分类超平面, 再把属于类 x_j 的样本从样本集中剔除, 顺次进行下去, 得到基于聚类思想的二叉树 SVM 分类模型; ⑦ 算法结束。

4 仿真结果及分析

仿真实验以受试者 k3b 的数据处理结果为例, 仿真环境为 CPU T4400 2.2GHz, RAM 1.99GB, Windows XP SP3, MATLAB R2009a。

4.1 脑电信号的预处理结果

原始脑电信号是一种非平稳性比较突出且微弱的随机信号, 其在采集过程中很容易受到外界的干扰, 如心电、眼电、以及工频干扰等噪声信号, 使得信号的波形呈现无节律性, 本文使用基于小波变换的消噪, 其可以把待分析的脑电信号按频率分为多个频段, 灵活的处理噪声所处的频段, 最后重构去噪后的小波系数, 实现消噪。

以 C3、C4 导的信号为例进行小波消噪, 图 4 为 C3 导 EEG 信号小波消噪前后的波形图, 图 5 为 C4 导 EEG 信号小波消噪前后的波形图。从图 4 和图 5 可以看出 C3、C4 导原始信号振荡比较明显, 存在明显的工频干扰。由小波消噪后的结果可以看出此时的信号波形振荡明显减小, 变得比较平滑, 即小波变换能有效的检测并消除工频干扰, 提高了信噪比。

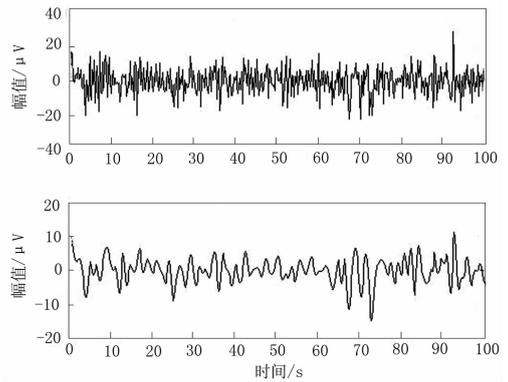


图 4 C3 导 EEG 信号小波消噪前后波形图

Fig. 4 EEG signals of C3 channel before and after the wavelet denoising

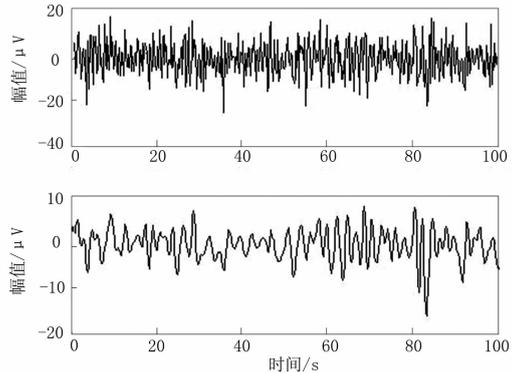


图 5 C4 导 EEG 信号小波消噪前后波形图

Fig. 5 EEG signals of C4 channel before and after the wavelet denoising

4.2 脑电信号特征提取的结果

利用小波包分析方法提取 EEG 特征时, 由于本文分析的脑电数据的采样频率为 250Hz, 其奈奎斯特 (Nyquist) 频率为 125Hz, 又考虑到与运动极为相关脑电信号的频段范围和最大限度的提取出有用信息, 本文利用相应的小波包函数将 4 个通道预处理后的信号分解为 6 层, 共把信号划分为 32 个频段。但是所得到的频带并不是按照频率的大小连续排列的, 表 1 给出了 6 级小波包分解系数和频带的对应关系。

表 1 小波包分解系数和频带的对应关系

Table 1 Wavelet packet coefficient vs. frequency band

系数	0	1	2	3	4	5	6	7
频带	0	1	3	2	7	6	4	5
系数	8	9	10	11	12	13	14	15
频带	15	14	12	13	8	9	11	10

因为脑电 ERD/ERS 模式主要体现在 α 节律和 β 节律的频段, 即 8~30Hz 之间, 所以根据小波包系数和频带之间的对应关系将需要的系数提取后再根据小波包算法进行相应的重构。为了进一步减少

特征数据的维数, 本文提取了所需频段重构后信号的能量特征构造表征信号的特征向量。其提取的 4 类运动想象脑电信号的特征波形图如图 6 所示。

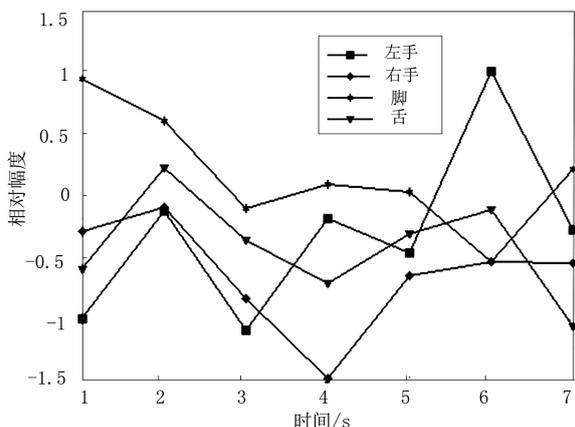


图 6 4 类运动想象脑电信号的特征波形图

Fig. 6 EEG feature waveforms of four-class motor imagery

从图 6 中可以发现, 最容易分的类是由想象右手和脚运动产生的脑电信号, 那么在 SVM 分类器中就可以先分离出来, 而想象左手和舌运动的脑电特征波形幅值之间相差比较微弱, 使得这两类运动产生的脑电信号在 SVM 分类器中分类不太明显, 因此其分类准确率会相对较低。

4.3 分类结果

本文通过预处理阶段随机选取 3 个受试者 K3b, K6b 和 L1b 的 200 次试验。选取 140 个作为训练集, 剩下的作为测试集。经小波包重构后获得的能量特征信号送入基于聚类思想的二叉树 SVM 分类器进行训练、分类, 并以分类准确率作为评价分类效果的有效依据。将本文方法与文献 [4, 10] 和 BCI 竞赛以及传统的“一对一”方法的分类结果进行比较, 结果见表 2。

表 2 分类正确率比较 %

Table 2 Classification accuracy comparison %

方法	K3b	K6b	L1b
本文算法	91.12	79.89	86.25
文献 [4]	85.71	—	—
文献 [10]	86	—	—
BCI 竞赛	86.67	81.67	85.00
一对一方法	90.08	80.02	85.94

由表 2 可见, 与其他分类方法相比, 本文提出的算法分类正确率有了一定的提高, 最高能达到 91.12%。一方面是由于二叉树 SVM 克服了拒分问题, 另一方面是由于二叉树 SVM 每个 SVM 的

核参数可单独调整, 更有利于分类准确率的提高。

5 结论

将基于聚类思想的二叉树与 SVM 结合在一起解决多类任务分类问题, 在分类正确率方面取得了较好的结果, 而且克服了拒分区域, 降低了“误差累积”效应的影响, 从而提高了分类推广能力, 可以将这些特征转化为某种控制信号控制外部辅助运动设备, 就可以帮助生活不能自理的患者通过计算机与外界环境进行交流和沟通, 因此在脑机接口的应用中具有一定的使用价值。

参考文献:

- [1] Millan del R J. On the need for on-line learning in brain-computer interfaces [C] //Proceedings of 2004 IEEE International Joint Conference on Neural Networks. Budapest: Institute of Electrical and Electronics Engineers Incorporation Publisher, 2004: 2877 - 2882.
- [2] WILSON J A, MELLINGER J, SCHALK G, et al. A procedure for measuring latencies in brain-computer interfaces [J]. IEEE Transactions on Biomedical Engineering, 2010, 57 (7): 1785 - 1797.
- [3] Vapnik V N. 统计学习理论的本质 [M]. 北京: 清华大学出版社, 2000.
- [4] 万柏坤, 刘延刚, 明东, 等. 基于脑电特征的多模式想象动作识别 [J]. 天津大学学报: 自然科学与工程技术版, 2010, 43 (10): 895 - 900.
- [5] YANG B H, YANA G ZH, YAN R G, et al. Adaptive subject-based feature extraction in brain-computer interfaces using wavelet packet best basis decomposition [J]. Medical Engineering & Physics, 2007, 29 (1): 48 - 53.
- [6] 蔡新波. 基于脑电信号的电动轮椅控制方法研究 [D]. 杭州: 杭州电子科技大学, 2012.
- [7] 黄玲, 张爱华. 改进的决策树 SVM 在脑电识别中的应用 [J]. 计算机工程与设计, 2010, 31 (2): 382 - 384.
- [8] 赵志刚, 吕慧显, 李玉景, 等. 一种基于聚类思想的 SVM 多类分类方法 [J]. 青岛理工大学学报: 自然科学版, 2011, 32 (1): 73 - 76.
- [9] 薛欣, 贺国平. 基于隶属度分离测度 SVM 决策树层次结构设计方法 [J]. 计算机应用研究, 2007, 24 (9): 162 - 167.
- [10] TANG Yan, TANG Jing-tian, GONG An-dong. Multi-class EEG classification for brain computer interface based on CSP [C] //Proceedings of the 1st International Conference on BioMedical Engineering and Informatics. Sanya: Institute of Electrical and Electronics Engineers Computer Society Press, 2008: 469 - 472.