

一种新的基于小波包分解的 EEG 特征抽取与识别方法研究

王 登, 苗夺谦, 王睿智

(同济大学计算机科学与技术系, 上海 201804; 同济大学嵌入式系统与服务计算教育部重点实验室, 上海 201804)

摘 要: 为了提高脑思维任务分类精度, 提出一种新的脑电特征抽取与识别方法. 首先进行小波包分解, 然后结合能反映脑电信号在时域与频域上的能量分布特征的小波包熵概念, 从小波包库中选择最优小波包基, 对各个最优基所对应的小波系数求取统计特性, 然后根据不同脑思维任务下左右半球各导联间的差异性对各个导联对求取不对称率构成分类特征向量, 最后利用 SVM 分类器对其进行分类. 实验结果表明: 相对于一般的小波包分解, 最优小波包基和自回归特征抽取方法, 该方法对 5 类不同脑思维任务的所有 10 种不同组合任务对的平均分类预测精度可以达到 95.41% ~ 99.65%.

关键词: 非平稳脑电信号; 特征抽取; 小波包分解; 脑机接口

中图分类号: R318 **文献标识码:** A **文章编号:** 0372-2112 (2013)01-0193-06

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2013.01.33

A New Method of EEG Classification with Feature Extraction Based on Wavelet Packet Decomposition

WANG Deng, MIAO Duo-qian, WANG Rui-zhi

(Department of Computer Science and Technology, Tongji University, Shanghai 201804, China;

Key Laboratory of Embedded System and Service Computing, Ministry of Education, Tongji University, Shanghai 201804, China)

Abstract: In order to improve accuracy of mental task classification, we propose a new method of EEG classification with feature extraction. First, the raw signals are decomposed by wavelet packet decomposition (WPD). Then, using wavelet packet entropy reflecting the distribution of signal energy in time and frequency domains, the best basis of wavelet packets is selected from a wavelet packet library according to the wavelet packet entropy. Afterwards the statistical features are used to represent the best basis wavelet coefficients. Moreover, the eigenvector is obtained by calculating the asymmetry ratio of the hemispheric brainwave at each electrode in different mental tasks. Finally, the performance of the eigenvector is evaluated via a support vector machines classifier. A publicly available EEG database was used to validate this study. Compared to the conventional WPD, wavelet packet best basis decomposition and existing autoregressive feature extraction methods, the average accuracy for the proposed method ranged from 95.41% to 99.65% for ten different combinations of five mental tasks.

Key words: nonstationary EEG signal; feature extraction; wavelet packet decomposition; brain-computer interface

1 引言

为了帮助人们更好的探索脑的活动机制并推动脑电信号 (Electroencephalogram, EEG) 在脑机接口 (Brain-computer Interface, BCI) 中的应用, 探讨高效的处理算法和不同脑思维任务下的模式挖掘并提供相应的解释这一研究越来越多地受到国内外研究者的关注和重视. 脑电信号分析与处理是信号处理与机器学习研究中一个最具挑战性的课题之一. 从处理算法层次上讲, 主要的研究方向包括脑电数据预处理、特征抽取、特征选择

及分类预测等. 其中, 特征抽取是本文关注的重点.

特征抽取就是以特征信号作为源信号, 确定各种参数并以此为向量组成表征信号特征的特征向量^[1]. 特征抽取作为脑电数据分类处理的关键步骤, 对最后的分类结果有着重要的影响, 国内外很多研究人员都在进行不懈地探索^[2~13]. 目前已有的特征抽取方法有经典的时域、频域和时-频域结合分析方法. 由于仅使用单一的时域或频域信息来提取 EEG 特征, 使得 EEG 识别率通常不高. 而时-频域结合的方法相对于单一类别信息法则提供更多的信息, 常见的方法有: 时-空模式分析、统计

分析、混沌分析、信源分解、空间滤波方法、利用特定频带的功率谱、自回归模型、快速傅里叶变换、小波变换以及小波包变换等. Anderson 等^[3]使用自回归 (Autoregressive, AR) 模型进行脑电信号的特征抽取, 并采用 2 和 3 层前向型神经网络对 4 个被试 5 种认知进行 10 折交叉验证, 平均分类正确率 38 ~ 71%. 杨帮华等^[4]提出基于小波包分解的 EEG 信号特征抽取方法对两种不同的思维活动进行分类, 取得较好的效果. 李明爱等人^[5]采用离散小波变换 (DWT) 抽取 EEG 特征, 使用 BP 神经网络对想象左右手运动进行分类, 获得了 92.4% 的正确率. 基于小波包分解的小波包基和小波熵脑电信号 EEG 特征抽取提供了一种更加精细的分析方法, 是近年来发展起来的一种新的特征表示手段, 展现出诱人的研究与应用价值^[4,6~13].

本文在小波包分解的基础上, 提出一种新的基于小波包分解 EEG 特征抽取算法. 该算法是在获取最优小波包基的基础上, 有效的利用了脑区功能对不同脑思维任务脑电信号的不同节律, 求取左右半脑各导联间的不对称率的来完成特征抽取, 最后利用 SVM 对其进行分类. 实验结果表明, 相对传统小波包特征抽取方法, 最优小波包基特征抽取方法和自回归特征抽取方法, 该算法表现出明显的优势: 在随机选择 50% 作为训练数据, 剩余 50% 作为测试数据情况下, 对 5 类不同脑思维任务的 10 种不同组合任务对的分类预测可以达到 95.41% ~ 99.65% 的正确率.

2 脑电信号特征抽取

2.1 小波包分解

小波包分解 (Wavelet Packet Decomposition, WPD) 是一种有效的信号时频分析方法, 它是将信号投影到一组互相正交的小波基函数张成的空间上, 并将信号分解成低频和高频两部分, 在下一层分解中它不仅对信号的低频部分进行分解, 同时也能够对高频部分实施再分解, 是一种更为精细的分析方法. 小波包分析基本理论^[14]简介如下:

小波包变换的二尺度方程如下, 其中 h_{0k}, h_{1k} 是多分辨率分析中的滤波器系数:

$$\begin{cases} w_{2n}(t) = \sqrt{2} \sum_{k \in Z} h_{0k} w_n(2t - k) \\ w_{2n+1}(t) = \sqrt{2} \sum_{k \in Z} h_{1k} w_n(2t - k) \end{cases} \quad (1)$$

当 $n=0$ 时, $w_0(t) = \phi(t)$ 为尺度函数, $w_1(t) = \psi(t)$ 为小波函数. 定义函数序列 $\{w_n(t)\}_{n \in Z}$ 为由 $w_0(t) = \phi(t)$ 所确定的小波包.

小波包系数递推公式为

$$\begin{cases} d_k^{l+1, 2n} = \sum_l h_{0(2l-k)} d_l^{l, n} \\ d_k^{l+1, 2n+1} = \sum_l h_{1(2l-k)} d_l^{l, n} \end{cases} \quad (2)$$

2.2 基于小波包分解特征抽取方法

由于脑电信号是非线性的非平稳信号, 而小波包提供了一种能在频域和时域同时分析非平稳时变信号的特点, 因此该方法首先采用小波包分解技术对每一段 EEG 数据进行低频和高频分解, 得到所有频段的小波包库. 然而, 对于给定的正交小波, 一个长度为 $N = 2^L$ 的信号的分解方式最多可以有 2^L 种, 即一个深度为 L 的完整二叉树的子树数目, 该值往往比较大. 在完整的二叉树结构中, 并非所有二叉树都有价值. 因此, 产生了如何实现小波包最佳分解的问题. 针对这个问题, Coifman 等人^[11]在 1992 年提出了在小波包分解过程中的最佳基选择准则, 其基本分解流程是一种类似于二叉树的结构, 以划分后的子空间中的熵作为进一步划分的准则, 当一个结点对应于空间中的熵大于该结点的下一级子结点对应的两个子空间的熵之和时, 才接受该种划分, 以此为划分准则, 一直划分下去, 直到不可再划分为止. 另外, 信息理论中的小波熵是用来对不确定性进行度量, 应用到脑电信号上, 它能反应脑电信号在时域与频域上的能量分布特征. 文献^[12]也采用小波熵来提取脑电信号特征, 结合欧式距离判别准则对两类思维脑电进行分类, 获得了 96.97% 的结果. 为此我们结合小波熵的概念, 在小波包分解后, 对每一频段仍然比较复杂的脑电信号计算小波包熵来度量脑电信号在时域与频域上的能量分布特征. 对频率波段 m 定义小波包熵如下:

设 E_1, E_2, \dots, E_m 为信号 $x(t)$ 在 m 个尺度上的小波能谱, 则在尺度域上的小波能谱可以形成对信号能量的一种划分. 在此, 采用正交小波, 可知在某一时间窗内 (窗宽为 $W \in N$) 信号总能量 E 等于各分量能量 E_j 之和, 即 $E = \sum_{j=1}^m E_j$, 式中 E_j 是小波包熵. Shannon 熵定义如下:

$$E(s) = - \sum_i s_i^2 \log(s_i^2) \quad (3)$$

满足 $E(0) = 0$. 其中 s 代表信号, s_i 代表信号 s 在一个正交小波包基上的投影系数.

另外, 我们知道, 从头表上记录到的 EEG 通常来自多个导联的脑电信号, 不同的导联取自不同的脑部位, 记录不同脑区在同一脑思维任务下的活动情况. 因此, 不同的脑思维任务反映到各导联所记录的信号就会包含有差异性的信息量. 研究发现, 大脑在不同脑思维任务下表现出不同的半球专门化效应. 但一般而言, 针对不同的认知思维活动, 大脑两半球均参与相应的认知

加工,但分工不同并表现出一定的大脑单侧化效应。Doyle 在文献[15]提出相对于空间(spatial)任务而言,在口头(verbal)和算术(arithmetic)任务中, α 波(8~13Hz) Fourier 功率普能量在大脑左右半球的比率较为显著。该文献同时发现相对于输出运动的任务(motor)而言,不需要输出运动的任务(non-motor,比如为信件打腹稿)表现出较弱的左右半脑不对称性。大脑左右半脑专门化效应的研究由来已久,但是关于专门化效应的问题还存在众多争议。早在上世纪七十年代,研究者们就开始使用脑电波技术来测量大脑半球专门化效应。众多的研究者们发现脑电波的不对称性会随着认知任务的不同而变换。起初这种不对称性的研究多是来自被试看到或听到某种外部刺激后作出运动活动时记录的脑电信号。文献[16]开始使用左右半脑电极谱密度曲线研究不需要输出运动的任务下特定波段(α 波)的不对称性,进而揭示半球专门化效应。Keim 和 Aunon^[17]则认为仅靠单一的 α 波求取左右半脑导联的不对称率来区分脑思维任务不是很有效的,因此该文献对四个频率波段(δ, θ, α 和 β)均使用 Wiener-Khinchine 方法估计普密度,然后分别求取各导联间不对称率来区分脑思维任务,取得了较好的效果。综上可以得出,对于不同的脑思维任务,不仅左右半脑存在差异,相应的各导联间也存在差异,因此不妨利用左右半脑各导联的组合对求取不对称率作为分类特征。具体算法如下:

(1)选用小波包函数对每一段 EEG 数据进行小波包分解,得到一个完全分解树。

(2)对树中每个结点 $N_{i,j}$ 按照式(3)计算第 i 层中的第 j 个结点小波包熵 $E_{i,j}$ 。

(3)基于最小小波熵原则求取最优小波包基树。具体步骤为:沿叶子结点向根结点,对非叶子结点 $N_{i,j}$,如果 $E_{i,j} \leq E_{i+1,k}$ ($E_{i+1,k}$ 是结点 $N_{i,j}$ 所有子结点 $N_{i+1,k}$ 的熵值总和),则结点 $N_{i,j}$ 将被保留为最优树的一个结点,其下的子结点被去除。否则,结点 $N_{i,j}$ 的熵值被 $E_{i+1,k}$ 替代,子结点保留。按从左到右、从下往上的顺序依次进行最优基的选择,直到根结点为止,最终得到整棵最优树,即最优基的集合。该步骤的实质是在信息损失较少的前提下,使信号中隐含的信息能集中反映在少数几个分解系数上,以实现信号的分解和重建。

(4)对最优小波包基树中的每一结点按照式(2)求取其小波包系数。

(5)为了进一步降低特征维数,对每一组小波包系数求取统计特性包括最大值、最小值、均值和方差,形成统一的四维向量。在后面介绍的实验中,每组数据中均是 6 导数据,其中 3 导数据来自左半脑($C3, P3, O1$),3 导来自右半脑($C4, P4, O2$),所以对于一个数据段可以得到 2 个 3×4 向量。

(6)按照下列组合:($C3, C4$), ($C3, P4$), ($C3, O2$), ($P3, C4$), ($P3, P4$), ($P3, O2$), ($O1, C4$), ($O1, P4$), ($O1, O2$)求取不对称率 $(R-L)/(R+L)$ 。其中, L 来自左半脑导联, R 来自右半脑导联。将这 9 个四维向量构成 1×36 向量作为对应数据段信号的特征向量。

3 SVM 分类器

支持向量机(Support Vector Machines, SVM)是根据统计学理论提出的一种机器学习方法^[18]。它已经逐渐成为解决模式分类问题的首选工具。给定一个带标签的分类样本集为 (x_i, y_i) , $i = 1, 2, \dots, n$, 其中 $x_i \in R^d$, x 为特征向量, n 为样本数量, $y \in \{+1, -1\}$ 为类别标号,通过寻找一个最优超平面把他们最大间隔的分开,在增大间距的同时,引入错误惩罚进行权衡优化。由于 SVM 分类器是参数化的分类器,其泛化性能在很大程度上依赖于参数的选取,是一个很重要的研究问题。由于参数最优化并不是本文的重点,故在后面的分类测试试验中,我们首先选择径向基 $K(X_i - X) = \exp(-\gamma \|X_i - X\|^2)$ 作为核函数,满足 Mercer 定理, $\gamma > 0$ 为核参数,然后采用机械的网格化的方法(即损失参数 C 和核参数 γ 分别从一个下限到一个上限来找其中满足最佳分类效果所对应的 C 和 γ)交叉验证完成最优参数选择。

4 实验

4.1 数据和预处理

为了评价算法的有效性,同时方便和已有的文献相比较,本文采用美国科罗拉多州大学思维脑电数据库的五种不同脑思维任务的脑电数据^[19]。实验中,被试坐在隔音且光线微弱的房间里,头戴电极帽,电极按国际 10-20 系统标准安放在 $P3, P4, C3, C4, O1, O2$ 的位置,左眼上面和下面单独放两个电极,取它们的均值作为眼电信号(EOG)。模拟带通滤波范围为 0.1~100Hz,采样频率 250Hz。要求被试分别完成五种不同的脑思维任务(如表 1 所示)。每次思维任务采集数据的时间为 10 秒,故每个数据样本都是一组 7×2500 的数据阵列。每个任务重复 5 次作为一个 Session,共采集 2 个 Session 数据。

在进行特征抽取之前,首先对数据进行一些必要的预处理,包括原始 EEG 信号异常点更正、EEG 分段及眼电(EOG)去除。首先,对每一个导联中的所有原始 EEG 样本点,把大于样本平均值 95% 的点或小于样本平均值 5% 的点分别用样本平均值 $\times 0.95$ 及样本平均值 $\times 0.05$ 替代,从而完成异常点更正。接着,我们采用文献[20]和[22]使用的分段方法,对 6 导联信号用矩形窗进行分段,每段数据长度 0.5s(125 个样本点),下一

段与上一段数据重叠 0.5s, 这样每一个脑电任务 10s 数据共分为 39 段数据样本, 如图 1 所示. 对于眼电 (EOG) 去除, 我们没有采用通过肉眼观察去除的方法, 而是采用仅去除 EOG 数据幅值变化最大的前 9 段数据, 即对每次实验保留 EOG 变化小的 30 段所对应的 6 导联数据.

表 1 五种不同的脑思维任务

序号	任务	描述
1	静息状态 (Baseline, B)	仅要求被试尽可能放松, 不进行任何思维活动.
2	心算乘法 (Multiplication, M)	给被试呈现比较复杂的乘法运算 (如: 49×78), 让其仅进行心算. 任务时间结束后才允许被试验证答案.
3	信件腹稿 (Letter-composing, L)	要求被试想象给某位朋友或亲人写一封信, 且多次实验中信件内容不能重复.
4	几何图形旋转 (Rotation, R)	给被试观看一个复杂三维几何图形, 30 秒时间之后要求被试想象将这个三维图形绕某个轴旋转.
5	想象在黑板上书写数字 (Counting, C)	要求被试想象将数字按顺序一个写一个写在黑板上.




图 1 脑电数据沿时间轴分段

表 2 WPD, 最优小波包基与本文的 WPD 方法 (IWPD) 对任意两种不同思维脑电数据的分类实验结果比较 (%)

Task	Subject 1			Subject 2			Subject 3			Subject 4		
	WPD	BWPD	IWPD	WPD	BWPD	IWPD	WPD	BWPD	IWPD	WPD	BWPD	IWPD
B vs. M	68.60	90.93	98.43	59.93	83.47	100.00	54.23	95.37	99.20	91.27	98.80	92.60
B vs. L	45.30	99.33	100.00	64.33	93.13	100.00	47.37	97.63	98.73	86.70	74.28	94.21
B vs. R	68.97	92.57	100.00	86.93	89.93	99.80	54.67	96.17	99.90	68.93	77.33	97.67
B vs. C	53.07	81.33	96.80	57.13	93.73	99.60	44.00	97.97	100.00	84.03	87.47	98.70
M vs. L	58.97	96.77	95.10	79.73	85.60	100.00	44.73	97.07	99.30	51.89	59.65	91.61
M vs. R	48.00	92.77	100.00	81.60	92.73	100.00	54.90	98.13	96.20	55.60	78.20	95.77
M vs. C	48.93	98.80	94.37	50.33	88.07	99.33	43.97	99.00	98.37	46.20	83.03	95.40
L vs. R	66.20	94.57	98.67	93.47	93.13	99.33	54.80	96.53	98.37	42.32	75.37	94.60
L vs. C	54.50	94.50	92.80	77.13	93.80	99.60	42.57	97.93	98.77	60.21	88.07	99.30
R vs. C	54.57	97.20	95.70	71.00	90.00	98.87	47.40	95.03	99.10	63.37	80.70	94.23
Average	56.71	93.88	97.19	72.16	90.36	99.65	48.86	97.08	98.79	65.05	80.29	95.41

另外, 为了在同等条件下比较, 本文也按照文献 [21] 介绍的 AR 方法编程实现特征抽取 (取 6 阶的模型阶数, 运用 Burg 法对每段数据进行 AR 参数估计, 得到长度为 6 导 \times 6 阶 = 36 的系数序列构成一个特征向量). 最后采用上面介绍的 SVM 分类器进行训练和分类. 与 IWPD 相比较 (如表 3 所示), 四个 Subject 的平均

在实验中, 考虑个体的差异性 (因为不同的个体也许会使用不同的认知策略来完成同一种认知任务), 本文对每一个体单独求取特征向量, 在分类阶段通过交叉验证寻找满足该个体的最佳分类器参数, 最后对其进行分类.

4.2 实验结果与分析

本文选取 Subject 1 ~ Subject 4 的所有五类不同脑思维任务的数据. 其中, 被试 1 和 2 分别是左力手 48 岁和右力手 39 岁大学男教师, 被试 3 和 4 都是年龄在 20 - 30 岁的右力手男大学生. 在分类测试中, 每个被试均随机选用所有 2 个 Session 的 50% 数据作为训练样本, 5 折交叉验证求取 SVM 中的最优参数, 剩余作为测试样本, 在使用 SVM 分类器之前训练样本和测试样本分别进行 0 到 1 归一化操作. 实验选用 Db2 小波函数对每一段 EEG 数据进行 5 层小波包分解, 利用上述方法, 对每个被试的任意两种不同思维脑电数据进行了分类, 重复 10 次取平均. 表 2 是使用传统的小波包分解 (WPD) 方法, 最优小波包基 (BWPD) 方法和本文提出的小波包分解 (IWPD) 方法对五类不同脑思维任务的所有组合得到的分类结果. 从分类结果可以看出, 不同的实验个体之间识别效果存在一定的差异, 不同思维任务的组合对识别率也具有一定的影响. 从整体上讲, IWPD 方法得到更好的分类结果: 97.76% (4 个 Subject 的平均分类精度).

分类精度也比 AR 方法高 31.56%. 其中, 所采用的 AR 模型如下:

$$y_{i,c}(t) = - \sum_{i=1}^p a_{i,c} x_{i,c}(t-i) \quad (4)$$

其中, $a_{i,c}$ 为导联 C 的第 i 个 AR 系数, $C = \{P3, P4, C3, C4, O1, O2\}$, p 为 AR 模型的阶数. 6 导 \times 6 阶

特征向量为: $(\alpha_{1,P3}, \alpha_{1,P4}, \alpha_{1,C3}, \alpha_{1,C4}, \alpha_{1,O1}, \alpha_{1,O2}, \alpha_{2,P3}, \alpha_{2,P4}, \alpha_{2,C3}, \alpha_{2,C4}, \alpha_{2,O1}, \alpha_{2,O2}, \dots, \alpha_{6,P3}, \alpha_{6,P4}, \alpha_{6,C3}, \alpha_{6,C4}, \alpha_{6,O1}, \alpha_{6,O2})$.

最后,表 4 列出在与文献[22]分类精度的比较结果.与本文不同的是,该文献采用的分类器是 BP 算法训练的多层感知神经网络(MLP-BP).实验结果表明,对于不同的任务组合,本文提出的特征抽取方法结合 SVM 分类器均表现出显著的优势.四个 Subject 平均分类精度比固定自回归(Fixed Autoregressive, FAR)和自适应自回归(Adaptive Autoregressive, AAR)分别提高 23.67%和 35.47%.分析发现,经典的时变 AR 模型虽能反映了信号的时变特性,但数据段的长度决定了参数估计的分辨率及准确度.换句话说,长度越短,时间分辨率越高,但是模型估计的误差增大.

表 4 与文献[22]讨论的 Fixed autoregressive (FAR), Adaptive AR (AAR)方法的分类结果比较(%)

Task	Subject 1			Subject 2			Subject 3			Subject 4		
	FAR	AAR	IWPD	FAR	AAR	IWPD	FAR	AAR	IWPD	FAR	AAR	IWPD
B vs. M	80.20	68.50	98.43	74.50	61.60	100.0	67.85	50.00	99.20	86.10	72.70	92.60
B vs. L	76.80	60.90	100.0	80.60	64.20	100.0	59.85	51.80	98.73	63.30	57.50	94.21
B vs. R	76.25	65.10	100.0	70.90	57.40	99.80	74.25	63.40	99.90	80.95	81.80	97.67
B vs. C	82.20	64.20	96.80	71.30	63.60	99.60	57.60	51.60	100.0	76.40	69.40	98.70
M vs. L	82.65	68.40	95.10	74.30	62.20	100.0	71.15	50.00	99.30	78.20	74.30	91.61
M vs. R	82.55	76.70	100.0	68.85	54.30	100.0	71.55	50.00	96.20	75.20	66.70	95.77
M vs. C	83.10	64.70	94.37	72.95	53.90	99.33	63.40	49.90	98.37	92.70	77.60	95.40
L vs. R	72.30	65.00	98.67	73.90	63.10	99.33	76.65	60.50	98.37	72.55	70.70	94.60
L vs. C	68.80	59.90	92.80	88.80	65.90	99.60	61.85	56.50	98.77	71.35	64.50	99.30
R vs. C	72.05	53.60	95.70	66.00	50.20	98.87	69.90	56.30	99.10	73.75	73.20	94.23
Average	77.69	64.70	97.19	74.21	59.64	99.65	67.41	54.00	98.79	77.05	70.84	95.41

5 结论

本文提出的一种新的小波包分解特征抽取方法是从新的角度结合小波包能量分析,最优小波包基求取与不同导联间在不同脑思维任务下的差异,即根据左右半脑的各个导联对求取不对称率来提取脑电特征向量.同时考虑个体的差异,本文针对每一个体单独求取特征向量,在分类阶段通过交叉验证寻找满足该个体的最佳分类器参数.实验结果证明了这种特征提取与分类方法的结合可以很好地区分五类不同脑思维任务的所有十种不同组合任务对.本研究为 BCI 脑思维任务下脑电信号的特征提取与分类提供了新的思路,具有一定的应用前景.

参考文献

- [1] 杨立才,李佰敏,李光林,贾磊.脑-机接口技术综述[J].电子学报,2005,33(7):1234-1241.
Yang L C, Li B M, Li G L, Jia L. A review of brain-computer

表 3 文献[21]介绍的 AR 方法和本文的 WPD 方法对任意两种不同思维脑电数据的分类实验结果比较(%)

Task	Subject 1		Subject 2		Subject 3		Subject 4	
	AR	IWPD	AR	IWPD	AR	IWPD	AR	IWPD
B vs. M	66.50	98.43	89.33	100.0	57.60	99.20	67.50	92.60
B vs. L	49.67	100.0	67.00	100.0	80.23	98.73	71.72	94.21
B vs. R	58.90	100.0	80.87	99.80	48.33	99.90	56.70	97.67
B vs. C	48.83	96.80	77.40	99.60	77.40	100.0	84.70	98.70
M vs. L	57.83	95.10	95.20	100.0	74.57	99.30	58.11	91.61
M vs. R	66.07	100.0	80.27	100.0	45.90	96.20	49.73	95.77
M vs. C	50.20	94.37	80.07	99.33	60.20	98.37	50.57	95.40
L vs. R	50.37	98.67	90.53	99.33	68.83	98.37	60.14	94.60
L vs. C	44.30	92.80	71.60	99.60	86.93	98.77	92.74	99.30
R vs. C	44.57	95.70	74.07	98.87	52.13	99.10	60.27	94.23
Average	53.72	97.19	80.63	99.65	65.21	98.79	65.22	95.41

interface technology[J]. Acta Electronica Sinica, 2005, 33(7): 1234-1241. (in Chinese)

- [2] 徐宝国,宋爱国,费树岷.在线脑机接口中脑电信号的特征提取与分类方法[J].电子学报,2011,38(5):1025-1030.
Xu B G, Song A G, Fei S M. Feature extraction and classification of EEG in online brain-computer interface[J]. Acta Electronica Sinica, 2011, 38(5): 1025-1030. (in Chinese)
- [3] Anderson C W, Stolz E A, Shamsunder S. Multivariate autoregressive models for classification of spontaneous electroencephalographic signals during mental tasks[J]. IEEE Trans Biomed Eng, 1998, 45(3): 277-286.
- [4] 杨帮华,颜国正,严荣国.脑机接口中基于小波包最优基的特征抽取[J].上海交通大学学报,2005,39(11):1879-1882.
Yang B H, Yan G Z, Yan R G. The feature extraction in brain-computer interface based on best basis of wavelet packet[J]. J Shanghai Jiaotong Univ, 2005, 39(11): 1879-1882. (in Chinese)

- [5] 李明爱,王蕊,郝冬梅. 想象左右手运动的脑电特征提取及分类研究[J]. 中国生物医学工程学报, 2009, 28(2): 166 - 170.
Li M A, Wang R, Hao D M. Feature extraction and classification of EEG for imagery left-right hands movement[J]. Chin J Biomed Eng, 2009, 28(2): 166 - 170. (in Chinese)
- [6] Yildiz A, Akin M, Poyraz M, Kirbas G. Application of adaptive neuro-fuzzy inference system for vigilance level estimation by using wavelet-entropy feature extraction[J]. Expert Syst Appl, 2009, 36(4): 7390 - 7399.
- [7] Yang B H, Yan G Z, Yan R G, Wu T. Feature extraction for EEG-based brain computer interfaces by wavelet packet best basis decomposition[J]. J Neural Eng, 2006, 3: 251 - 256.
- [8] Xue J Z, Zhang H, Zheng C X, Yan X G. Wavelet packet transform for feature extraction of EEG during mental tasks [A]. Proceedings of the 2nd International Conference on Machine Learning and Cybernetics[C]. IEEE, 2003. 360 - 363.
- [9] Wang D, Miao D Q, Xie C. Best basis-based wavelet packet entropy feature extraction and hierarchical EEG classification for epileptic detection[J]. Expert Syst Appl, 2011, 38(11): 14314 - 14320.
- [10] Wu T, Yang G Z, Yang B H, Sun H. EEG feature extraction based on wavelet packet decomposition for brain computer interface[J]. Measurement, 2008, 41(6): 618 - 625.
- [11] Coifman R, Wickerhauser M V. Entropy-based algorithms for best-basis selection[J]. IEEE Trans Inf Theory, 1992, 38: 713 - 718.
- [12] 孙宇舸,叶柠,徐心和. 基于小波熵和距离的脑电信号特征提取与识别[A]. 中国控制与决策学术年会论文集[C]. 烟台, 2008. 4294 - 4298.
Sun Y G, Ye N, Xu X H. The feature extraction and recognition of EEG based on wavelet entropy and distance [A]. Prceedings of Chinese Control and Decision Conference[C]. Yantai, 2008. 4294 - 4298. (in Chinese)
- [13] 任亚莉. 基于小波包熵的运动意识任务分类研究[J]. 生物物理学报, 2008, 24(3): 227 - 231.
Ren Y L. Study on classification of imaginary hand movements based on wavelet packet entropy[J]. Acta Biophysica Sinica, 2008, 24(3): 227 - 231. (in Chinese)
- [14] 孙延奎. 小波分析及其应用[M]. 北京: 机械工业出版社, 2005.
Sun Y K. Wavelet Analysis and Application[M]. Beijing: China Machine Press, 2005. (in Chinese)
- [15] Doyle J C, Ornstein R, Galin D. Lateral Specialization of cognitive mode: II. EEG frequency analysis[J]. Psychophysiology, 1974, 11(6): 567 - 578.
- [16] Ehrlichman H, Wiener M S. EEG asymmetry during covert mental activity [J]. Psychophysiology, 1980, 17(3): 228 - 235.
- [17] Keirn Z A, Aunon J I. A new mode of communication between man and his surroundings[J]. IEEE Trans Biomed Eng, 1990, 37(12): 1209 - 1214.
- [18] Cortes C, Vapnik V. Support-vector network [J]. Machine Learning, 1995, 20: 273 - 297.
- [19] Colorado State University [DB/OL]. [http://www. cs. colostate. edu/eeg/eegSoftware. html](http://www.cs.colostate.edu/eeg/eegSoftware.html).
- [20] Nakayama K, Inagaki K. A brain computer interface based on neural network with efficient pre-processing[A]. Proceedings of the IEEE, ISAPCS2006[C]. Yonago, 2006. 673 - 676.
- [21] Anderson C W, Sijercic Z. Classification of EEG signals from four subjects during five mental tasks[A]. Proceedings of the IEEE, EANN'96[C]. London, 1996. 407 - 414
- [22] Huan N J, Palaniappan R. Classification of mental tasks using fixed and adaptive autoregressive models of EEG signals[A]. Proceedings of the 26th Annual International Conference of the IEEE EMBS[C]. San Francisco, 2004. 507 - 510.

作者简介



王 登 男, 1976 年生于陕西西安. 同济大学博士研究生. 研究方向为生物医学工程, 智能信息系统, 神经科学等.

E-mail: w_deng208@hotmail.com



苗夺谦 男, 1964 年生于山西祁县. 同济大学电子与信息工程学院教授、博士生导师、副院长. 研究方向为智能信息处理, 人工智能与模式识别, 数据挖掘, 粗糙集与粒计算等.

E-mail: miaoduoqian@163.com