

基于矩阵灰建模的单次 P300 检测新方法

谢松云,张娟丽,段 绪,刘 畅,李亚兵

(西北工业大学电子信息学院,陕西西安 710072)

摘 要: 针对少导联 P300 单次提取识别率较低的问题,提出了一种基于矩阵灰建模的参数模型法提取特征的方法,提高了 P300 单次识别率. 首先对脑电信号进行预处理,然后选择导联组合,接着对每个 Epoch 进行建模,将模型参数作为特征向量输入 SVM 分类识别. 结果表明,单次 P300 的平均识别率为 91.43%,叠加平均 3 次正确率可高达 97.87%.

关键词: P300 特征提取; 矩阵灰建模; 单次识别

中图分类号: TP391.4

文献标识码: A

文章编号: 0372-2112 (2017)07-1660-08

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2017.07.016

A New Single Trial P300 Classification Method Based on Matrix Grey Modeling

XIE Song-yun, ZHANG Juan-li, DUAN Xu, LIU Chang, LI Ya-bing

(School of Electronics and Information, Northwestern Polytechnical University, Xi'an, Shaanxi 710072, China)

Abstract: Aiming at the drawback of low identification accuracy in single trial P300 feature extraction and classification, a parameter model method based on Matrix Grey Modeling to extract P300 feature was proposed to improve the recognition accuracy of the visual evoked potential P300 in single trial classification. Firstly, EEG signal was preprocessed, and then channel set selection was applied. After that, the model parameters of Matrix Grey Modelling for each epoch was connected as the feature vector and were input to the SVM classifier. The experimental results show that the average accuracy of single trial P300 across all the subjects is 91.43%, and the accuracy can be up to 97.87% if 3 times averaging is used.

Key words: P300 feature extraction; matrix grey modeling; single trial identification

1 引言

P300(也称为 P3b)是能反映高级认知处理过程的一个内源性成分,是事件相关电位中投入研究最多、应用最广、最引人注目的成分之一. 它是在被试辨认“靶刺激”时,在头皮记录到的潜伏期约为 300ms 的最大晚期正波,可由视觉、听觉和体感刺激诱发, P 代表正波“positivity”, 300 代表潜伏期 300ms.

P300 电位被广泛应用于脑-机接口系统 (Brain Computer Interface, BCI) 和测谎研究中. 基于 P300 的 BCI 系统因其无需训练,操作简单而备受研究者的关注. 虽然到目前为止有多种基于不同信号的 BCI 系统被相继提出,但基于 P300 的脑-机接口应用是最广的^[1]. 同时, P300 作为一种内源性成分,其和注意、记忆相关,

在心理学方向已经被成功应用到测谎领域^[2]. 无论是 BCI 系统还是基于 P300 的测谎研究中,实现少试次/单次提取 P300 一直是生物医学工程领域研究的热点. 传统的 P300 识别方法是采用时域相干平均的方法,通过叠加平均可以有效减少背景随机噪声. 此方法可以很好地识别 P300,但是存在明显的缺陷:多次平均忽略了不同试次之间的差异,并且不能满足实时性的要求,不利于 P300 的现实应用. 为了克服上述问题,研究者们提出了多种方法实现少次/单次 P300 的特征提取,如基于小波变换的识别算法^[3]、基于独立分量分析的识别算法^[4,5]、基于主成分分析的识别算法^[6]等. 王攀等提出了一种将时域能量熵和离散小波变换相结合的特征提取方法,在 2 次叠加平均后,正确率可达到 95%^[7]. Li Kun 等提出了一种基于独立成分分析的单次 P300 分类

方法,他们通过 ICA 的方法提取 P300 的特征,实现 P300 的分类识别,单次分类正确率为 76.67%^[8]. 陈洪波等提出一种基于 Informax ICA 少次自动提取脑电信号 P300 成分的方法,6 试次实验数据经过所给方法处理后得到了和 P300 模板较大的相关系数,但未给出识别正确率^[9]. 文献[10]中,研究者采用方差分析的方法单次检测 P300,平均正确率为 84.8%. 也有研究者直接采用极限学习机(Extreme Learning Machine, ELM)学习样本的特征分布,达到了较好的单次识别率,平均正确率为 85%^[11]. 文献[12]对 EEG 信号提取 3 层 Haar 小波系数,然后进行分类,虽然在 5 试次叠加后达到了相当好的分类效果(100%),但是单次分类只达到 61.29% 的正确率. 综上所述可以得出,单次提取 P300 的正确率仍然有提升的空间,研究提高单次提取 P300 正确率的方法仍然具有现实意义.

面向矩阵的灰建模是将传统灰建模中的点序列扩展到面序列,实现对矩阵序列的少数据、少样本的精确建模. 基于矩阵序列的灰建模可以将空间信息和时间信息同时进行建模,是一种时-空分析方法^[11]. 目前,还没有人将此方法应用到 P300 分析检测中,研究尚属空白.

针对上述问题和研究现状,本文提出一种基于矩阵灰建模的方法进行 P300 分类识别,首次将灰色理论中的矩阵灰建模用于 P300 的特征提取中,结合使用支持向量机(Support Vector Machine, SVM)分类器实现对单次少导联 P300 的检测识别. 实验结果表明,此方法可以通过对单次 P300 的精确建模,将其模型参数作为 P300 的特征,在单次 P300 检测中可以达到较高的识别率. 如果进行少试次的叠加处理,此方法可达到更高的识别率.

2 单次 P300 检测方法

2.1 EEG 预处理

首先对原始数据进行 1~15Hz 的带通滤波,滤波器选择巴特沃斯滤波器;然后根据数据标签进行分段,选取刺激前 0.1s 至刺激后 0.7s 的数据,分段为 0.8s 的 Epoch;接着,对分段后的 Epoch 进行伪迹剔除,将最大幅值和最小幅值差大于 140 μ V 的数据段标记为噪声伪迹,进行剔除,不参与后续的数据处理. 最后,将刺激前 100ms 的数据的平均值作为基线,对刺激后的数据进行基线矫正. 我们对一个被测预处理后的导联 CH35 上所有样本数据进行时域叠加平均,叠加平均后其时域波形图如图 1 所示.

2.2 导联组合选择

脑电记录为 64 导联,其电极放置图如图 2 所示. 根据前人研究成果,P300 成分在顶枕区比较明显,因此选取此区域的部分导联进行分析,以选择最佳导联组合

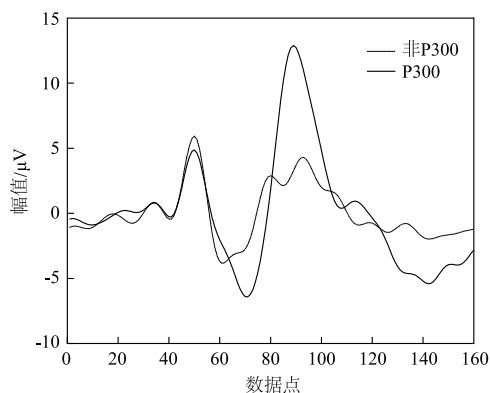


图1 目标刺激和标准刺激下样本叠加波形

用以后续处理分类. 我们通过观察采集的训练数据,画出目标与非目标的波形图,从而选择合理的导联组合. 具体做法为:重点选取顶枕区的 CH33、CH34、CH35、CH36、CH37、CH38、CH39、CH40、CH42,画出 P300 和非 P300 所有样本的平均波形,如图 3 所示,并且选择 P300 峰值最大,即波形差异最明显的前 4 个导联作为最优电极. 由图 3 可见,CH35、CH37、CH39、CH40 这 4 个导联均有明显的 P300 波,而且和无关刺激下的非 P300 波存在较大差异,因此选取此 4 个电极记录的脑电信号作为后续分析处理的数据.




图2 电极放置图

2.3 特征提取

2.3.1 对角矩阵灰建模

面向矩阵的灰建模是对传统灰建模的延伸和扩展,其把点时间序列中的点抽象成空间平面,就如同图像帧序列中的每一个图像帧,这样可以得到基于空间平面的序列集^[13]. 此处,用矩阵表示这样的空间平面,则可以得到一个如图 4(b) 所示的矩阵序列.




图3 顶枕区各个导联所有样本平均的P300和非P300波形：实线代表P300，虚线代表非P300




图4 点时间序列和矩阵序列

在实际应用中可能不需要关注矩阵平面中的所有信息,而只需要关注矩阵平面的部分信息或关键特征信息;同时,还希望矩阵序列灰建模能变得简单有效.因此,在矩阵序列灰模型的基础上,对矩阵灰模型(Matrix Grey Model, MGM)进行改进,即对角变换矩阵序列灰模型(Diagonal Transformation Matrix Sequence Grey Model, DTMGM).

定义 1 $\mathbf{x} = (\mathbf{x}(1), \mathbf{x}(2), \dots, \mathbf{x}(k), \dots, \mathbf{x}(n))$, 其中 $\mathbf{x}(k)$ 是一个 $m \times m$ 阶的矩阵, $k \in \{1, 2, \dots, n\}$. 设 $\lambda_1^k, \dots, \lambda_m^k$ 为矩阵平面 $\mathbf{x}(k)$ 的特征值, $\mathbf{v}_1^k, \dots, \mathbf{v}_m^k$ 为矩阵平面 $\mathbf{x}(k)$ 的特征向量.

记 $\mathbf{x}^{(0)}(k) = \text{diag}(\lambda_1^k, \dots, \lambda_m^k)$,

$\bar{\mathbf{x}}^{(0)}(k) = \text{diag}(\mathbf{v}_1^k, \dots, \mathbf{v}_m^k)$.

那么, $\mathbf{x}^{(0)} = (\mathbf{x}^{(0)}(1), \mathbf{x}^{(0)}(2), \dots, \mathbf{x}^{(0)}(n))$,

$\bar{\mathbf{x}}^{(0)} = (\bar{\mathbf{x}}^{(0)}(1), \bar{\mathbf{x}}^{(0)}(2), \dots, \bar{\mathbf{x}}^{(0)}(n))$

是由矩阵序列 \mathbf{x} 经对角变换而得的两个矩阵序列.

经对角变换,原始序列信息集中在主对角线上.基于对角变换的矩阵序列灰建模过程如下.

$\mathbf{x}^{(0)}$ 的一阶累加生成矩阵 $\mathbf{x}^{(1)} = \text{MAGO}(\mathbf{x}^{(0)})$, 表示为:

$$\mathbf{x}^{(1)} = (\mathbf{x}^{(1)}(1), \mathbf{x}^{(1)}(2), \dots, \mathbf{x}^{(1)}(k), \dots, \mathbf{x}^{(1)}(n)) \quad (1)$$

其中,

$$\mathbf{x}^{(1)}(k) = \sum_{q=1}^k \mathbf{x}^{(0)}(q) = \text{diag} \left(\sum_{q=1}^k \lambda_1^q, \sum_{q=1}^k \lambda_2^q, \dots, \sum_{q=1}^k \lambda_m^q \right).$$

定义 2 对角变换矩阵序列灰模型(Diagonal Transformation Matrix Sequence Grey Model, DTMGM)如下

$$\mathbf{x}^{(0)}(k) + \mathbf{z}^{(1)}(k) = \text{diag}(a_1, a_2, \dots, a_m) \quad (2)$$

其中, $\mathbf{z}^{(1)}(k) = 0.5\mathbf{x}^{(1)}(k) + 0.5\mathbf{x}^{(1)}(k-1)$,

$$\mathbf{z}^{(1)}(k) \in \mathbf{z}^{(1)} = (\mathbf{z}^{(1)}(2), \dots, \mathbf{z}^{(1)}(n)).$$

$z^{(1)}(i, i, k)$ 是 $\mathbf{z}^{(1)}$ 中第 k 个矩阵平面上坐标点 (i, i) 的值, $z^{(1)}(i, i, k) = 0.5\mathbf{x}^{(1)}(i, i, k) + 0.5\mathbf{x}^{(1)}(i, i, k-1)$, $\forall k \in \{2, 3, \dots, n\}, i \in \{1, 2, \dots, m\}$.

此模型可记为 DTMGM(1, 1 + m). DTMGM(1, 1 + m) 为 1 阶, 1 + m 个参数的对角变换矩阵序列灰模型. a 为发展系数, $\text{diag}(a_1, a_2, \dots, a_m)$ 为灰作用量.

DTMGM(1, 1 + m) 的白化模型为

$$\frac{d\mathbf{x}^{(1)}}{dt} + a\mathbf{x}^{(1)} = \text{diag}(a_1, a_2, \dots, a_m) \quad (3)$$

其中, $[a, a_1, a_2, \dots, a_m]^T$ 为 DTMGM(1, 1 + m) 模型的参数向量, 记为 \mathbf{p}_{dm} .

参数向量 \mathbf{p}_{dm} 在最小二乘准则下有矩阵算式:

$$\mathbf{p}_{dm} = [a, a_1, a_2, \dots, a_m]^T = (\mathbf{B}^T \mathbf{B})^{-1} \mathbf{y}_n \quad (4)$$

$$\text{其中, } \mathbf{y}_n = \begin{bmatrix} x^{(0)}(1, 1, 2) \\ x^{(0)}(2, 2, 2) \\ \vdots \\ x^{(0)}(i, i, k) \\ \vdots \\ x^{(0)}(m, m, n) \end{bmatrix},$$

$$\mathbf{B} = \begin{bmatrix} -z^{(1)}(1, 1, 2) & 1 & 0 & \dots & 0 \\ -z^{(1)}(2, 2, 2) & 0 & 1 & \dots & 0 \\ \vdots & & & & \\ -z^{(1)}(i, i, k) & & & 1 & \\ -z^{(1)}(m, m, n) & & & \dots & 1 \end{bmatrix}.$$

\mathbf{y}_n 是一个 $m(n-1) \times 1$ 阶矩阵, \mathbf{B} 是一个 $m(n-1) \times (1+m)$ 阶矩阵. $x^{(0)}(i, i, k), z^{(1)}(i, i, k)$ 是矩阵序列 $\mathbf{x}^{(0)}, \mathbf{z}^{(1)}$ 中第 k 个矩阵平面上 (i, i) 坐标点的值. 矩阵 \mathbf{B} 的后 m 列由 0 和 1 构成. 在这 m 列中, 第一列的第一个元素值为 1, 其后的元素每隔 m 个元素为 1, 其余全为 0. 与此相似, 第 h 列的第 h 个元素值为 1, 其后的元素每隔 m 个元素为 1, 其余全为 0.

对于原始序列 \mathbf{x} 的对角变换矩阵 $\mathbf{x}^{(0)}$ 和 $\mathbf{x}^{(1)}$ 的矩阵累加生成序列 $\mathbf{x}^{(1)}$, DTMGM(1, 1+m) 白化模型的响应方程式为

$$\mathbf{x}^{(1)}(k+1) = (\mathbf{x}^{(0)}(1) - \frac{\mathbf{D}}{a})e^{-ak} + \frac{\mathbf{D}}{a} \quad (5)$$

$$\mathbf{x}^{(0)}(k+1) = \mathbf{x}^{(1)}(k+1) - \mathbf{x}^{(1)}(k) \quad (6)$$

其中, $\mathbf{D} = \text{diag}(a_1, a_2, \dots, a_m)$.

原始序列 \mathbf{x} 的模拟和预测序列可通过式(7)式(8)得到.

$$\hat{\mathbf{x}} = (\hat{\mathbf{x}}(1), \hat{\mathbf{x}}(2), \dots, \hat{\mathbf{x}}(k), \hat{\mathbf{x}}(k+1), \dots) \quad (7)$$

$$\hat{\mathbf{x}}(k) \in \hat{\mathbf{x}}, \hat{\mathbf{x}}(k) = (\bar{\mathbf{x}}^{(0)}(k))\hat{\mathbf{x}}^{(0)}(k)(\bar{\mathbf{x}}^{(0)}(k))^{-1} \quad (8)$$

$\hat{\mathbf{x}}^{(0)}(k)$ 可以通过 DTMGM(1, 1+m) 的白化响应方程式得到, $\bar{\mathbf{x}}^{(0)}(k)$ 可由序列 \mathbf{x} 的对角变换而得.

应用 DTMGM 对 1s 时间的 EEG 数据的建模模拟效果如图 5 所示.




图5 DTMGM对EEG的建模拟合效果
(蓝色为原始数据, 红色为拟合输出)

2.3.2 基于 DTMGM 的 P300 特征提取方法

空间上, 对 4 个导联进行矩阵变换, 写成 2×2 的矩阵形式; 时间上, 对每个 Epoch 的 160 点数据划分成 20 个 8 点数据. 这样, 每段数据样本每 8 个时间点进行 $2 \times 2 \times 8$ (DTMGM(1, 1+2)) 的矩阵灰建模, 可得到 20 个 DTMGM(1, 1+2) 模型, 每个样本得到 20 个 2 维的参数向量. 图 6 显示了 Epoch 经过分段建模后提取的模型参数分别随时间的变化分布情况.

由图 6 可以看出, DTMGM(1, 1+2) 的 2 维模型参数随时间的变化分布和 P300 的波形吻合, 并且在两种状态下有明显差异; 特别是第一维模型参数和原波形有基本相同的潜伏期, 说明分段的 DTMGM 方法加强了 P300 的波形特点, 有效提取了目标波形的特征.




图6 两种状态下分段建模后的特征参数分布(横坐标为分段序号)

2.4 基于 Fisher 比率法的特征选择

Fisher 比率方法用于估计某一特征的有效性, 作为一个品质因数在特征选择方面得到广泛应用. Fisher 比率定义为类间均值的方差与类内平均方差的比值, 该方法选出的特征类间差距大, 类内差距小^[14].

将经过上述方法得到的 2 个 20 维的特征向量拼接为 40 维特征向量, 然后进行 Fisher 比率的计算, 按照比率值的大小进行排序, 得到排序后每个特征对应的序号. 最后根据特征排序选择最优特征空间. 图 7 表示不同维数特征空间的分类正确率, 正确率为所有被试正确率的平均值.

由图 7 可以看出, 当选择前 6 个特征(特征空间维数为 6)时, 已经达到较高的准确率, 说明我们提的特征包含有效信息. 当特征空间维数在 1~20 之间变化时, 正确率保持稳定, 而随着特征空间的增大, 正确率缓慢降低, 说明特征空间存在着冗余特征, 进行特征选择是必要的. 因此, 我们最终选择前 20 个特征作为特征向量, 进行最终的分类识别.

2.5 分类识别

支持向量机是 Corinna Cortes 和 Vapnik 等人于 1995 年在统计学习中的 VC 维理论和结构风险最小化原理的基础上提出的. 它的基本思想就是将数据映射到一个高维空间, 并在其上寻找一个能将数据正确分类的最大间隔超平面. 支持向量机在解决小样本、非线性及高维模式识别中表现出许多特有的优势^[15]. 因此, 本文选择支持向量机作为分类器, 实现对 P300 的识别分类.

2.6 方法描述

上述方法的流程图如图 8 所示.




图7 不同特征空间的分类正确率




图8 本文方法流程图

3 P300 实验数据获取

3.1 刺激材料和任务

实验过程中在屏幕中央随机显示刺激标准刺激“X”或者靶刺激“O”,标准刺激出现的概率为 80%,靶刺激出现的概率为 20%.实验开始时,屏幕中央出现一个“+”注视点,在随机时间 800 ~ 1200ms 后,出现刺激字符“X”或“O”,显示时间为 1000ms.被试在看到靶刺激“O”出现时需要摁键反应,每个试次以一个黑屏结束.

被试为 8 名在校大学生志愿者,平均年龄为 23 周岁,视力均为佩戴眼镜矫正至正常视力.实验在一个电磁屏蔽室进行,被试端坐于显示屏前,双眼平视屏幕中心,距离屏幕 70cm.实验过程中,要求被试注视屏幕中央,当出现“X”时,不做任何动作,出现“O”时,尽快准确地按下响应盒按键,实验期间刺激呈现时要求被试不能眨眼,每 30 个试次后有一个休息时间.实验设计如图 9 所示.

3.2 EEG 记录

采用美国 EGI 公司的 NetAmp300 的 64 导脑电记录分析系统,电极的放置采用国际 10-20 系统标准.同时记录 64 导 EEG 数据,Cz 导联作参考电极,皮肤-电极阻抗均降至 5kΩ 以下,采样频率为 200Hz.实验每个被试总共采集 300 试次数据,其中靶刺激为 60 试次,非靶刺激为 240 试次.

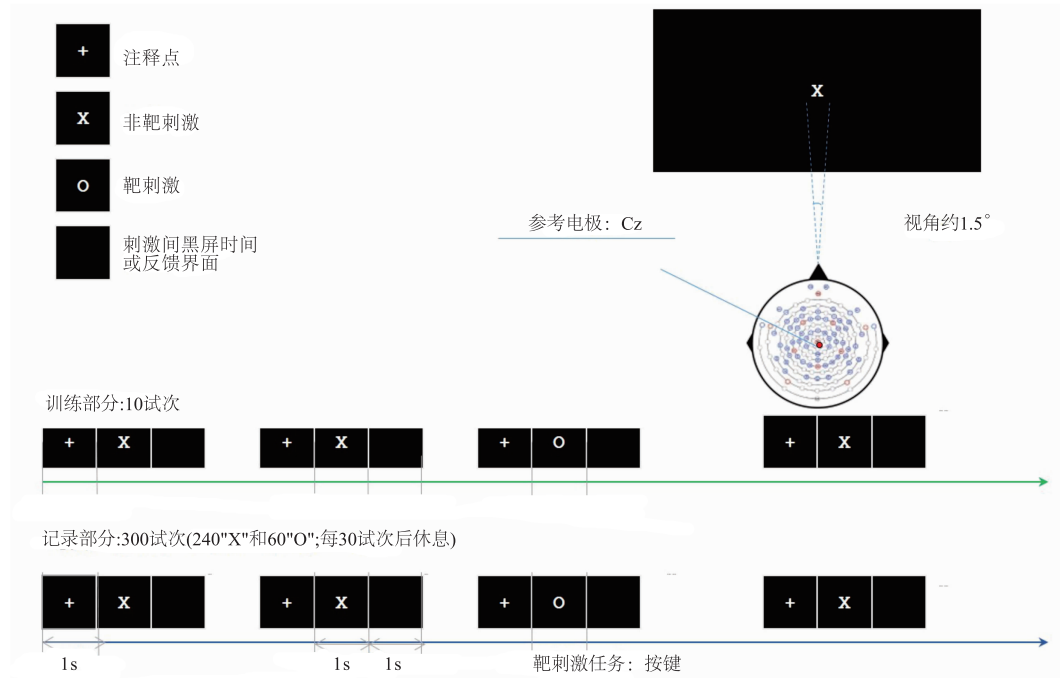


图9 X-O双刺激Oddball实验设计

4 实验结果与分析

按照 2.2 所述方法最终选取 CH35、CH37、CH39 和

CH40 总共 4 个导联的信号,按上述方法提取出所有样本的 20 维特征向量,分别使用训练集和测试集对分类器进行训练和测试.采用 Matlab 自带的的支持向量机

SVM 作为分类器,根据不同核函数下的分类效果,选择 RBF 作为分类器的核函数,高斯核方差 σ 取 5.

交叉验证是一种评估算法对独立于训练数据的数据集的泛化能力,为了有效地估测本文多提出方法的有效性,分别采用三种不同的交叉验证方法即 Hold-out、k-折交叉验证($k = 10$)以及留一法进行分类.图 10 为每个被试不同交叉验证方法的正确率.

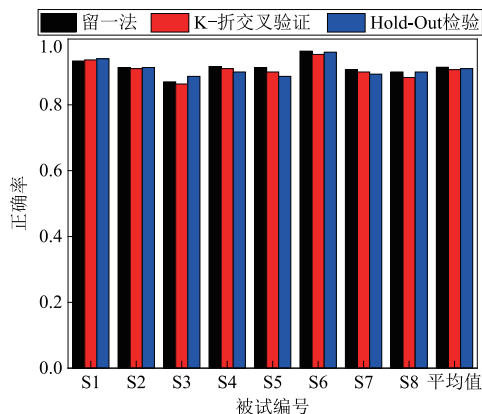


图10 不同交叉验证方法的分类正确率

由图 10 可以看出,三种交叉验证分类方法的平均正确率都超过了 90%,达到了较高的正确率,证明了所提出方法的有效性.三种交叉验证方法中,留一法的平均正确率最高,可能是因为留一法每一训练回合中几乎所有的样本皆用于训练模型,因此训练的模型最接近母体样本的分布,因此得到了最高识别正确率.将留一法得到的分类结果在表 1 中显示.

表 1 显示,所有被试的平均识别正确率达到 91.43%,分类正确率最高的一名被试可达 96.67%,即使效果最差的一名被试,也达到了 86.77%的正确率,证明本文方法是切实可行的.

为了说明本文方法的有效性和优越性,采用文献 [12] 提出的方法作为对比,即将每个 Epoch 进行 3 层 Haar 小波分解,并提取 4 个导联上小波分解的最大尺度上的低频系数作为特征向量,其方法在 8 个被试数据样本上的分类效果对比如图 11 所示.两种方法的实时性结果对比见表 2.

表 1 分类正确率 (%)

被试 ID	SVM	被试 ID	SVM
	'RBF'		'RBF'
1	93.4	5	91.3
2	91.43	6	96.67
3	86.77	7	90.77
4	91.67	8	90.0
平均正确率	91.43 ± 2.86		




图11 方法识别效果对比

表 2 实时性对比

对比方法	一个样本运行时间/s
小波分解	0.00436
本文方法	0.00948

由图 11 可以看出,本文提出的方法对每个被试的分类可以达到更高的正确率,除过被试 3 之外,其他被试的分类正确率均有较明显的提高.由表 2 可以看出,两者的运行时间在一个数量级上,均在 ms 级,但相比较起来,本文方法运行时间略高于小波分解方法,原因可能在于本文方法需要对每个样本进行分段处理,20 个分段然后建模增加了运行时间成本.如果只比较一次 DTMG 建模时间,其实时性是远远高于小波分解的.

以上结果可以看出,本文方法在单试次时已达到较高的识别率.为了进一步说明本方法的有效性,图 12 画出了当少试次叠加时所有被试的平均分类正确率(1 表示不叠加,即单试次).由图 12 可以看出,2 试次叠加平均后分类识别率达到 95%,继续增加叠加次数,在 3 试次叠加平均后,采用本文方法提取特征后分类正确率高达 97.87%,说明若叠加平均后使用本方法,正确率可进一步得到提高.




图12 不同叠加试次数的分类正确率

5 讨论与总结

本文采用了面向矩阵的灰建模方法对 P300 进行分段建模,并分析了模型参数的特点后,合理地将模型参数作为特征向量,采用 Fisher 比率值的方法进行特征降维,最后结合 SVM 分类器进行了分类识别,通过交叉验证的方法得到了可靠的分类结果,平均正确率达到 91.43%.

P300 电位由于其无损伤测量,无需训练等优点,在 BCI 研究领域以及认知测谎领域受到广泛关注. 基于操作方便和计算效率等方面的考虑,导联数目减少和单次 P300 检测成为当前研究热点. 本文提出一种基于矩阵灰建模的特征提取方法,将少量导联(4 导)信号经过分段建模后保留了原波形的特征信息并降低了信号维数. 通过与其他方法实验结果的对比,表明本文方法达到了较满意的识别正确率,提出的方法可以推广应用到其他基于 P300 的模式识别相关领域. 如果结合使用更好的分类算法如极限学习机(Extreme Learning Machine, ELM),分类正确率及稳定性将进一步提高,这是未来的研究方向之一.

参考文献

- [1] HOCHBERG L R, SERRUYA M D, FRIEHS G M, et al. Neuronal ensemble control of prosthetic devices by a human with tetraplegia [J]. *Nature*, 2006, 442 (13): 164 - 171.
- [2] ABOOTALLEBI V, MORADI M H, KHALILZADEH M A. A comparison of methods for ERP assessment in a P300-based GKT [J]. *International Journal of Psychophysiology*, 2006, 62(2): 309 - 320.
- [3] 闫蓓, 刘莎, 李建华, 袁海文, 丁锋. 单通道视觉诱发脑电的单次提取方法研究[J]. *仪器仪表学报*, 2012, 33(4): 905 - 910.
YAN Bei, LIU Sha, LI Jianhua, YUAN Haiwen, DING Fengfeng. Study on single-trial feature extraction method of single-channel visual evoked potential [J]. *Chinese Journal of Scientific Instrument*, 2012, 33(4): 905 - 910. (in Chinese)
- [4] 张宇, 张建华, 王行愚, 金晶. 基于 FastICA 的 P300 电位快速提取方法[J]. *华东理工大学学报(自然科学版)*, 2009, 35(5): 750 - 755.
ZHANG Yu, ZHANG Jian-hua, WANG Xing-yu, JIN Jing. A fast ICA-based approach to extracting P300 potential [J]. *Journal of East China University of Science and Technology (Natural Science Edition)*, 2009, 35(5): 750 - 755. (in Chinese)
- [5] 万柏坤, 朱欣, 杨春梅, 高扬. ICA 去除 EEG 中眼动伪差和工频干扰方法研究[J]. *电子学报*, 2003, 31(10): 1571 - 1574.
WAN Bai-kun, ZHU Xin, YANG Chun-mei, GAO Yang. Study on applying independent component analysis to remove blink artifacts and power noise in EEG [J]. *Acta Electronica Sinica*, 2003, 31(10): 1571 - 1574. (in Chinese)
- [6] AVIYENTE S, BERNAT E M, MALONE S M, et al. Time-frequency data reduction for event related potentials: Combining principal component analysis and matching pursuit [J]. *EURASIP Journal on Advances in Signal Processing*, 2010, 11(55): 289 - 571.
- [7] 王攀, 沈继忠, 施锦河. 基于小波变换和时域能量熵的 P300 特征提取算法[J]. *仪器仪表学报*, 2011, 32(6): 1284 - 1289.
WANG Pan, SHEN Jizhong, SHI Jinhe. P300 feature extraction algorithm based on wavelet transform and temporal energy entropy [J]. *Chinese Journal of Scientific Instrument*, 2011, 32(6): 1284 - 1289. (in Chinese)
- [8] LI K, SANKAR R, ARBEL Y, DONCHIN E. Single trial independent component analysis for P300 BCI system [A]. *Proceedings of the 31st Annual International Conference of the IEEE EMBS [C]*. USA: IEEE Press, 2009. 4035 - 4038.
- [9] 陈洪波, 李蓓蕾, 陈真诚. 基于 ICA 的脑电信号 P300 少次自动提取[J]. *电子学报*, 2012, 40(6): 1257 - 1262.
CHEN Hong-bo, LI Bei-lei, CHEN Zhen-cheng. Automatically extract P300 within several trials from EEG based on ICA [J]. *Acta Electronica Sinica*, 2012, 40(6): 1257 - 1262. (in Chinese)
- [10] LI Kun, et al. A new single trial P300 classification method [J]. *International Journal of E-Health and Medical Communications*, 2012, 3(4): 31 - 41.
- [11] XIE S, WU Y, ZHANG Y, et al. Single channel single trial P300 detection using extreme learning machine: Compared with BPNN and SVM [A]. *Proceedings of the International Joint Conference on Neural Networks (IJCNN) [C]*. China: IEEE Press, 2014. 544 - 549.
- [12] 杨立才, 李金亮, 姚玉翠. 基于小波分解和支持向量机的 P300 识别算法[J]. *中国生物医学工程学报*, 2007, 26(6): 804 - 809.
YANG Li-Cai, LI Jin-Liang, YAO Yu-Cui. P300 detection algorithm based on wavelet decomposition and support vector machines [J]. *Chinese Journal of Biomedical Engineering*, 2007, 26(6): 804 - 809. (in Chinese)
- [13] 刘歆. 面向矩阵序列的灰建模研究[D]. 四川重庆: 重庆大学, 2012.
- [14] CHEN Y W, LIN C J. Combining svms with various feature selection strategies [J]. *Studies in Fuzziness & Soft Computing*, 2005, 207: 315 - 324.

- [15] 丁世飞,齐丙娟,谭红艳. 支持向量机理论与算法研究综述[J]. 电子科技大学学报,2011,40(1):2-10.
DING Shi-fei, QI Bing-juan, TAN Hong-yan. An over-

view on theory and algorithm of support vector machines [J]. Journal of University of Electronic Science and Technology of China,2011,40(1):2-10. (in Chinese)

作者简介



谢松云 女,1968 年 4 月出生,福建人. 分别于 1997 年和 2001 年在西北工业大学获得硕士和博士学位,2013 年获得柏林工业大学博士后学位. 现为西北工业大学电子信息学院教授、博士生导师. 主要研究方向为目标跟踪与识别,神经信息处理以及灰色理论、机器学习等.
E-mail:syxie@nwpu.edu.cn



张娟丽 女,1989 年 2 月出生,陕西宝鸡人. 2011 年于西北工业大学获得工学学士学位,现为西北工业大学硕士研究生. 主要从事脑功能信号处理方法的研究.
E-mail:zjl_cathy@163.com