

ICA+CSSD的脑-机接口分类

唐 艳¹, 柳建新¹, 龚安栋^{1,2}

(1. 中南大学信息物理学院 长沙 410083; 2. 中南大学信息科学与工程学院 长沙 410083)

【摘要】针对复杂的脑电问题,介绍了一种对单次思维脑电信号提取、分类的方法。该方法的主要思想是将独立成分量和共空域子空间分解方法以及支持向量机学习方法结合起来,用于提取脑电信号特征。该方法分别被用于BCI Competition 2003 Data set IV和BCI Competition III Data set I,正确率分别达到了89%和92%。实验证明独立成分分量算法和共空域子空间分解方法能够很好地结合起来进行脑思维的分类,分类正确率很高,是一种快速、稳定可行的分解方法。

关键词 脑-机接口; 脑电信号; 独立分量分析; 支持向量机

中图分类号 R318

文献标识码 A

Classification of Brain-Computer Interfaces Using ICA+CSSD

TANG Yan¹, LIU Jian-xin¹, and GONG An-dong^{1,2}

(1. Department of Info-Physics Engineering, Central South University Changsha 410083;

2. Department of Information Science and Engineering, Central South University Changsha 410083)

Abstract Identification and classification technology plays an important part in study of the brain-computer interface (BCI) system. In this paper, an algorithm is presented to deal with the complex brain signals and extract features and classify single-trial electroencephalogram (EEG). The algorithm combines independent component analysis algorithm and common spatial subspace decomposition with support vector machine to extract features from multi-channel EEG and electrocorticogram (ECoG). This algorithm was applied to the results of data analysis show that the proposed method can classify with high accuracy.

Key words brain-computer interface; electroencephalograms; independent component analysis (ICA); support vector machine

脑-机接口的特点是对外界的控制信号不依赖肌肉神经活动,而依赖在头皮处测得的神经电位。因为头皮电位信号非常微弱,很容易被外界伪迹干扰,所以要求脑电信号分析、分类方法具有强鲁棒性^[1]。已经有许多方法用于判别和分类脑电信号,最常用的有效特征提取方法有^[2-3]:公共空间(common spatial subspace decomposition, CSSD)模型、自回归(autoregressive, AR)模型等。其中CSSD方法对事件相关去同化/同化(event-related desynchronization/synchronization, ERD/ERS)的处理非常有效。CSSD算法的思想是假设在高维空间中的两种情况分类,希望找到某个方向,使得一类方差最大的同时,另一类方差最小。

本文主要针对脑-机接口信号进行预处理,分类技术讨论,得到一种较为通用的判别方法。本文中以BCI Competition 2003的Data set IV和BCI

Competition III的Data set I为数据源,根据数据特点,首先用独立成分分析对数据进行分解,然后用CSSD方法对数据源空间定位得到特征向量,最后用支持向量机(support vector machine, SVM)进行数据分类,从而实现BCI任务识别。

头皮上测得的神经电位被认为是不同分布的头皮电位重叠,是不同脑电源活动的结果。因此EEG和ECoG数据都满足ICA假定的线性混合性^[4]。一般来说,采用ICA对EEG或ECoG信号进行分析,能够得到一些独立成分,它们分别代表不同脑电源和噪音。对得到的独立成分再进行CSSD算法分解,将其中最具有代表的几个特征向量组成特征值,放入SVM算法中进行训练、分类。本文的实验证明了这一通用算法的实用性和正确性。对Data set IV和Data set I两种不同类型的数据,同时取得了很好的分类效果,其分类的错误率分别为11%和8%,达到

收稿日期: 2006-10-08; 修回日期: 2008-04-05

基金项目: 湖南省自然科学基金(07JJ6045)

作者简介: 唐艳(1975-),女,博士生,讲师,主要从事生物信号处理方面的研究。

了最高识别率。并且,实验时可发现SVM训练中,采用ICA+CSSD得到的特征值比单独采用CSSD算法得到的特征值更加稳定,具有更强的鲁棒性。

1 关键技术及算法

1.1 ICA基础理论

假设源信号 $\mathbf{S}(t)=[s_1(t),s_2(t),\dots,s_N(t)]^T$ 是 N 个未知源信号矢量,则观测到的信号 $\mathbf{X}(t)=[x_1(t),x_2(t),\dots,x_M(t)]^T$ 可以写成:

$$\mathbf{X}(t)=\mathbf{A}\mathbf{S}(t) \quad (1)$$

式中 \mathbf{A} 是 $M \times N$ 维满秩混合矩阵。通过求解 $N \times M$ 列满秩混合分离矩阵 \mathbf{W} , 使得:

$$\mathbf{Z}(t)=\mathbf{W}\mathbf{X}(t) \quad (2)$$

式中 $\mathbf{Z}(t)=[z_1(t),z_2(t),\dots,z_M(t)]^T$ 是对未知源信号的估计。

ICA方法的判别依据根据度量各分量之间独立程度的判据不同^[5-6],有多种形式。本文采用负熵最大原则分析脑电信号,其中心思想是基于信息理论的熵的概念。随机变量的熵可解释为给定观察变量的信息度,信息度越随机,熵越大。在对信号进行ICA算法之前,先作白化处理。这种预处理有利于提高ICA性能。Infomax算法充分利用神经网络的知识,其原理是最大化一个具有非线性输出神经网络的输出熵(或信息流)。对负熵进行近似计算^[7]:

$$J(z_i)=k[E\{G(z_i)\}-E\{G(v)\}]^2 \quad (3)$$

式中 v 是与 z_i 具有相同方差的高斯随机变量。实验中取 $G(z_i)=\lg(\cosh(z_i))$ 。

根据 $\mathbf{Z}(t)=\mathbf{W}^T\mathbf{Y}(t)$, 从而得ICA的负熵判据相当于 $E\{G(\mathbf{w}^T\mathbf{y})\}$ 取极大值。在约束 $\|\mathbf{w}\|^2=1$, 构造如下目标函数:

$$F(\mathbf{w})=E\{G(\mathbf{w}^T\mathbf{y})\}+\lambda(\|\mathbf{w}\|^2-1)^2 \quad (4)$$

求 \mathbf{w} , 使得 $F(\mathbf{w})$ 取极大值,即相当于对 $F(\mathbf{w})$ 求导:

$$f(\mathbf{w})=\frac{\partial F(\mathbf{w})}{\partial \mathbf{w}} \quad (5)$$

可以得到ICA的递推公式:

$$\mathbf{w}(k+1)=\mathbf{w}(k)-f(\mathbf{w}(k))/f'(\mathbf{w}(k)) \quad (6)$$

对 \mathbf{w} 迭代一遍后,进行归一化:

$$\mathbf{w}(k+1)=\mathbf{w}(k+1)/\|\mathbf{w}(k+1)\| \quad (7)$$

迭代收敛后,就可求得到分离矩阵 \mathbf{W} , 进而得到分离出的独立分量:

$$\mathbf{Z}(t)=\mathbf{W}^T\mathbf{Y}(t) \quad (8)$$

1.2 共空域子空间分解算法思想

CSSD方法是一种在多任务条件下,从多通道EEG数据集中提取某一特定任务信号成分的方法。

许多实验结果表明这种方法适合于两种任务条件下的大脑信号分析,其分解原理可以参考文献[8-9]。CSSD方法的目的是设计与某个特定任务相关的空间过滤器,其步骤如下。

(1) 分别求出 a 、 b 两种类别的协方差矩阵:

$$\mathbf{R}_l=\mathbf{X}_l\mathbf{X}_l^T; \quad \mathbf{R}_t=\mathbf{X}_t\mathbf{X}_t^T \quad (9)$$

式中 下标 l 和 t 分别表示 a 、 b 。

(2) 分解协方差矩阵:

$$\mathbf{R}=\mathbf{R}_l+\mathbf{R}_t=\mathbf{U}_0\boldsymbol{\Sigma}\mathbf{U}_0^T \quad (10)$$

式中 $\boldsymbol{\Sigma}$ 为特征值对角阵; \mathbf{U}_0 为与其对应的特征向量矩阵。

(3) 构造白化值转换矩阵并转换协方差矩阵:

$$\mathbf{P}=\boldsymbol{\Sigma}^{-\frac{1}{2}}\mathbf{U}_0^T \quad (11)$$

然后将协方差矩阵 \mathbf{R}_l 和 \mathbf{R}_t 转换为如下形式:

$$\mathbf{Y}_l=\mathbf{P}\mathbf{R}_l\mathbf{P}^T; \quad \mathbf{Y}_t=\mathbf{P}\mathbf{R}_t\mathbf{P}^T \quad (12)$$

再将 \mathbf{Y}_l 和 \mathbf{Y}_t 进行特征值分解:

$$\mathbf{Y}_l=\mathbf{U}\boldsymbol{\Sigma}_l\mathbf{U}^T; \quad \mathbf{Y}_t=\mathbf{U}\boldsymbol{\Sigma}_t\mathbf{U}^T \quad (13)$$

(4) 构造空间过滤器:

应用主成分分析可知, $\boldsymbol{\Sigma}_l$ 和 $\boldsymbol{\Sigma}_t$ 中最大的一个或几个特征值所对应的特征向量就表征了左、右手指动作这两种任务。定义 $\boldsymbol{\Sigma}_l$ 和 $\boldsymbol{\Sigma}_t$ 中最大的几个特征值所对应的特征向量构成的矩阵分别为 \mathbf{U}_l 和 \mathbf{U}_t , 从而左、右手对应的空间过滤器分别为:

$$\mathbf{F}_l=\mathbf{U}_l^T\mathbf{P}; \quad \mathbf{F}_t=\mathbf{U}_t^T\mathbf{P} \quad (14)$$

1.3 支持向量机的分类思想

支持向量机是根据统计学理论提出的一种机器学习方法,它解决了小样本、非线性、高维数、局部极小点等实际问题。因为支持向量机能够实现快速分类,并处理高维输入向量问题,所以本文采用它作为学习算法^[10]。实验中,为了处理高维特征向量,支持向量机首先选取一个核函数,采用径向基核函数 $K(x,x_i)=\exp(-\|x-x_i\|^2/\sigma^2)$ 作为内积核函数。支持向量机中另一关键参数是惩罚因子,即综合考虑最少错分样本和最大分类间隔。采用ICA+CSSD结合处理脑电数据,可以看到支持向量机分类的结果稳定,不会因惩罚因子的不同而变化很大。

2 实验数据处理

实验中两组数据都是基于真实和想像运动,分别来自BCI Competition 2003 data set IV和BCI Competition III data set I,都具有事件相关去同化/同化特征。ERD信号的特点是真实或想像运动时,

感觉运动皮层的 μ (8~12 Hz)和 β (13~28 Hz)功率谱明显下降。data set IV是真实的运动任务,两类任务分别是左、右手运动。总共电极数为28个,采样频率为100 Hz。data set I数据来自一个癫痫病人想象舌头和左手小指的运动。采样率为1 000 Hz,64个电极,一共进行378次试验,实验难度在于训练的数据和测试的数据之间的间隔为一个星期。

本文以处理data set I数据为例,给出数据分析过程,与data set IV数据处理过程相同,但因为数据采用率为100 Hz(较低),没有进行降低空间维数的步骤,其他分析方法一致。

2.1 数据预处理

(1) 降低空间维数。Competition III data set I数据中,每次实验就有3 000个点,共进行了378次,数据量非常庞大,处理过程中首先必须进行下采样,降低数据维数。本文将采样率降低到250 Hz,即每次实验有750个采样点,有利于提高计算时间和保证足够的内存空间。同时,对64导联的数据进行选择,找出最能反映事件变化的导联。通过对训练数据的两类情况分别进行分析,比较各导联与平均谱和平均时域的差别,取其中标准方差最大的10个导联作为“好”的导联。通过实验,选择出12、21、22、29、30、31、38、39、40、46共10个导联的数据作为本文实验的数据源。可以看出,这些“好”的导联,其编号邻近,应该是靠近ECoG-ERD功能区的位置。

(2) 频率滤波。ERD信号的特点是在动作发生前 μ (8~12)和 β (13~28)波段的节律会有能量逐减的现象,并且具有大脑区域不对称性。实验中,主要利于该现象来识别不同情况的运动。考虑 μ 和 β 频段,本文对两类不同动作的数据分别进行带通滤波,滤波器采用的都是巴特沃思零相位滤波器,波段为8~30 Hz。

2.2 特征提取

(1) ICA空间滤波。将滤波后的10通道,全部训练数据(10×750×278),按每通道、每一次实验进行数据串接(两端数据接口处的数据要适当加以平滑)。先对信号进行白化处理,使得预处理后信号零均值、方差为1,从而除去信号的相关性,降低数据维数。然后采用Infomax ICA算法对处理后信号作ICA分解,得到10×10维解混阵 W 。

(2) CSSD空间滤波。将训练数据(共278次实验)按不同的类型分为两类,每一类为139次,对两组数据进行通带过滤,带宽为8~30 Hz,从而得到两组

数据 X_l 、 X_r ,分别代表左手小指的运动和舌头的运动。根据CSSD算法分别求出基于ERD的空间过滤器,其中 Σ_l 和 Σ_r 中取最大的两个特征值所对应的特征向量,最终得到 F_l 、 F_r 两个空间过滤器(维数都是2×10)。

(3) 特征提取。将所有实验数据都经过8~30 Hz带通滤波后,分别与解混阵 W 以及过滤器 F_l 、 F_r 相乘,得到相应的源 S_1 、 S_2 ,也就是每次实验都得到两个源,共得到训练数据和测试数据的大小分别为2×2×750×278和2×2×750×100(其中训练数据为278次;测试数据为100次):

$$S_1 = F_l \times W \times X; \quad S_2 = F_r \times W \times X \quad (9)$$

对每次实验的 S_1 和 S_2 分别取其2行(即取最大特征值对应的特征向量),定义10个特征 f_{11} 、 f_{21} 、 f_{12} 和 f_{22} 为:

$$\begin{cases} f_{1i} = \frac{\text{var}(S_{1i})}{\text{var}(S_{1i}) + \text{var}(S_{2i})} \\ f_{2i} = \frac{\text{var}(S_{2i})}{\text{var}(S_{1i}) + \text{var}(S_{2i})} \end{cases} \quad (10)$$

式中 i 表示第 i 行数据有750个; S_{1i} 、 S_{2i} 分别为 S_1 、 S_2 的第 i 行数据; var 表示求方差标准偏差数的平方。最后将可得到378×4个特征向量。分别将训练的特征向量278×4个作为输入,已标明的训练数据集作为目标矢量,组成训练样本对支持向量机进行训练。整个算法的处理流程如图1所示。得到支持向量机后,将测试的特征向量100×4进行分类,大于0的取1类,小于0的取-1类。




图1 信号处理流程

3 分类结果和讨论

采用以上方法提取训练数据的特征量作为支持向量机的输入,可以得到一个非常好的结果。在分类过程中,有几个关键的参数选择:

(1) 频域和时域过滤的选择,由先验经验可以知道ERD出现在 μ 和 β 频段,为了保证能够最有效地区分数据,事先对数据进行滤波处理,选取频段在8~30 Hz之间的数据作为有效数据;对于时域过滤方面,考虑到Competition III data set I数据量太大,本文采用了下采样,并选取10个最能反映事件区别的通道。

(2) 在构建空间滤波器过程中,首先将训练数据

进行ICA处理,得到解混阵 W ,从而能够得到一些独立成分,它们分别代表不同脑电源和噪音。然后将数据进行CSSD分解,在CSSD中采用几个最具有代表特征向量组成特征值是一个关键问题。在Competition III data set I数据分析中,对 Σ_1 和 Σ_2 中特征值个数的选取,进行了比较,如表1所示。发现分别取 Σ_1 和 Σ_2 两个特征值所对应特征向量时,分辨率最高。正确选择过滤器参数可以明显提高识别率。对于BCI Competition 2003 data set IV,最好情况下, Σ 中特征值也是选取2个数。

表1 特征值个数取值对错误率的影响

特征值个数	错误率/(%)
1	10
2	8
3	9

在空间滤波器构建过程中,还对单独用CSSD空间滤波和ICA+CSSD空间滤波两种情况进行结果分析。发现只用CSSD对数据进行空间滤波识别率与SVM中C的取值有很大关系。因此,先对数据进行ICA算法分解,再用CSSD比单独只用CSSD构建的特征值稳定性更大、区分度更大、更利于SVM分离。

(3) 支持向量机作为一种新的机器学习方法,具有较强的泛化能力,核函数和参数的选择对分类准确率具有一定的影响。由实验证明, σ^2 为核宽度,取值为0.2;C为不可分情况的惩罚系数,因为采用ICA+CSSD算法,在BCI Competition 2003 data set IV中分别取值10、50、100、500得到的效果一致,如表2所示。但是如果只用CSSD算法,C的取值是关键,不同的值将得到不同的错误率。在Competition III data set I中,同样可以发现ICA+CSSD空间滤波能够保证特征值稳定性,使其区分度更大。

表2 两种情况根据不同惩罚系数C得到不同错误率

惩罚系数C	CSSD/(%)	ICA+CSSD/(%)
10	8	8
50	9	8
100	9	8
500	9	8

4 结 论

本文采用时-空分析来识别EEG以及EcoG分

类,其中BCI Competition 2003 data set IV的识别率高达89%;Competition III data set I的识别率高达91%。分类的结果表明ICA与CSSD结合,利用ERD的信息,对EEG以及EcoG进行分类,在BCI研究中是一种有效的方法。国内外对脑-机接口信号处理,都仅仅采用CSSD方法实现,并没有将ICA与CSSD相结合。CSSD方法主要是获得信号源的空间信息,如果先将信号进行独立源分离,应该更有利于信号的空间投影。实际上,本文的实验结果也说明了这一想法的正确性。但是应该看到的是,针对手指动作时的EEG分类只是一种离线分析,离实际应用还有很大距离,因此,如何将这种有效方法应用于在线分析是下一步努力的方向。

参 考 文 献

- [1] RAJESH S. Environment control of using BCI[C]//ICBBE'07. Wuhan: IEEE, 2007: 1293-1295.
- [2] LIAO Xiang, YAO De-zhong, WU Dan, et al. Combining spatial filters for the classification of single-Trial EEG in a finger movement task[J]. IEEE Transactions on biomedical engineering, 2007, 54(5): 821-831.
- [3] DENNIS J M, CHARLES W A. BCI meeting 2005-workshop on BCI signal processing: Feature extraction and translation[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2006, 14(2): 135-137.
- [4] AN Bin, NING Yan, JIANG Zhao-hui. Classifying ECoG/EEG-based motor imagery tasks[C]//In: Proceedings of the 28th IEEE EMBS Annual International Conference. New York: IEEE, 2006: 6339-6342.
- [5] HYVARINEN A, KARHUNEN J, OJA E. Independent component analysis[M]. [S.l.]: John Wiley & Sons, 2001.
- [6] TANG Yan, TANG Jing-tian. Removal of ocular from EEG using JADE[C]//ICBBE'07. Wuhan: IEEE, 2007: 566-569.
- [7] 刘长生, 唐 艳, 汤井田. 基于独立分量分析的脑电中眼电伪迹的消除[J]. 计算机工程与应用, 2007, 43(17): 230-232.
- [8] WANG Y J, ZHANG Z G, LI Y. BCI competition 2003-data set IV: an algorithm based on CSSD and FDA for classifying single-trial EEG[J]. IEEE Transactions on Biomedical Engineering, 2004, 51(6): 1081-1086.
- [9] BLANCHARD G, BLANKERTZ B. BCI competition 2003-data set IIa: spatial patterns of self-controlled brain rhythm modulations[J]. IEEE Transactions on Biomedical Engineering, 2004, 51(6): 1062-1066.
- [10] GONG An-dong, CAI Zi-xing, TANG Yan. Distinguishing between left and right finger movement from EEG using SVM[C]//ICBBE'07. Wuhan: IEEE, 2007: 562-565.

编辑 熊思亮