

基于多特征融合的运动想象脑电信号识别研究

姜月, 邹任玲

上海理工大学医疗器械与食品学院, 上海 200093

【摘要】目的:脑机接口通过识别脑电信号后对外部设备进行控制,针对传统的提取单一特征方法无法多角度表征脑电,提出一种多特征融合的特征提取方法。**方法:**分别使用自回归模型、经验模态分解、共空间模式提取结合时-频-空域的初始特征向量,用主成分分析降维,最后用支持向量机分类。**结果:**对BCI2003数据处理后,得到91.9%的识别率,高于单一特征和两两组合特征下的识别率以及BP神经网络、概率神经网络的识别率。**结论:**多特征融合的特征提取方法更好地代表了脑电特征,同时采用支持向量机分类可取得较好的效果,证明本研究方法的有效性,可进一步用于脑机接口中。

【关键词】脑电识别;特征融合;主成分分析;支持向量机;运动想象

【中图分类号】R318

【文献标志码】A

【文章编号】1005-202X(2019)05-0590-07

Recognition of motor imagery EEG signals based on multi-feature fusion

JIANG Yue, ZOU Renling

School of Medical Instrument and Food Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China

Abstract: Objective The external devices are controlled with brain computer interface after the detection of electroencephalogram (EEG) signals. A feature extraction method based on multi-feature fusion is proposed to solve the problem that the traditional method of single feature extraction cannot realize the multi-angle characterization of EEG. **Methods** The initial eigenvectors of time-frequency-space domain were extracted by autoregressive model, empirical mode decomposition and common spatial pattern, separately. Subsequently, principal component analysis was used to reduce the dimension. Finally, support vector machine is used to classify the motor imagery EEG signals. **Results** After the data processing of BCI2003, the recognition rate reached 91.9%, higher than that obtained by the extraction based on single feature and the combination of any two features, and that obtained with BP neural network and probabilistic neural network. **Conclusion** Feature extraction method based on multi-feature fusion can characterize EEG better, and the combination with support vector machine can achieve better classification results, which proves the effectiveness of the combined use of multi-feature fusion and support vector machine. The proposed method can be further applied in brain computer interface.

Keywords: electroencephalogram recognition; feature fusion; principle component analysis; support vector machine; motor imagery

前言

脑机接口(Brain Computer Interface, BCI)是不依赖于大脑的正常输出通路(外周神经系统和肌肉组织),即可实现大脑与外界环境交流的一种人机交互方式,它通过对外部设备的控制使人们的意愿得到

表达。BCI系统利用采集的特定模式的脑电信号(Electroencephalogram, EEG)分析识别,转换为相应的控制命令,实现预期功能。BCI能否准确实现用户意愿,关键在于脑电识别率,直接影响着最终的控制准确度,而算法优化就是提高识别率的关键。

Gaur等^[1]采用经验模态分解(Empirical Mode Decomposition, EMD)提取频段能量等作为特征,采用线性判别分析分类,获得了70.2%的平均正确率。针对单一特征通常分类效果一般,目前很多研究开始组合使用不同特征提取方法。Peng等^[2]采用希尔伯特-黄变换(Hilbert-Huang Transform, HHT)提取自回归(Auto Regressive, AR)模型参数等作为特征,使

【收稿日期】2018-12-11

【基金项目】微创励志创新基金(YS30810174)

【作者简介】姜月,硕士研究生,主要研究方向:脑机接口、康复医疗器械, E-mail: jiangyue925h@163.com

【通信作者】邹任玲,博士,副教授,主要研究方向:康复医疗仪器、医疗器械检测, E-mail: zourenling@163.com

用支持向量机(Support Vector Machine, SVM)分类, 识别率达到91.65%。金海龙等^[3]利用HHT提取边际谱能量差, 并结合EEG时域复杂度作为特征量, 使用BP神经网络分类, 达到87.14%的识别率。Chatterjee等^[4]提取统计特征, 小波的能量、熵及均方根, 功率谱密度的平均功率、频带功率共26维特征向量, 分别使用SVM和多层感知器得到85.00%和85.71%的识别准确率。将不同特征结合更好地体现了EEG的有用信息, 为分类器提供更优的输入。

本研究提出利用EMD分解EEG得到内蕴模态函数(Intrinsic Mode Function, IMF), 提取其前三阶的能量值, 用共空间模式(Common Spatial Pattern, CSP)得到空域特征, 求取6阶AR模型系数, 将组合后的20维时-频-空特征向量采用主成分分析(Principle Component Analysis, PCA)降维, 新的低维特征用SVM分类, 并与其它算法比较, 验证本研究方法的有效性。

1 数据来源

为了客观评价算法的有效性, 本研究采用BCI2003中由Graz科技大学提供的脑电数据(Data set III)。受试者为1名25岁健康女性, 任务为根据屏幕的随机提示以想象左右手运动的方式控制目标左右移动。如图1所示, $t=0\sim 2$ s时, 受试者处于安静放松状态; $t=2$ s时, 出现声音提示实验开始, 并有“+”显示在屏幕上且保持1 s; $t=3$ s时, 向左或向右的箭头出现, 受试者想象左手或右手运动以使方块左右移动, 直至9 s结束。信号采集使用差分放大器和Ag/AgCl电极, 采集通道为国际标准10-20导联系统中的C3、Cz和C4这3个通道, 如图2所示。其中, C3和C4位于大脑初级感觉皮层运动区, 能有效反映肢体运动或想象运动时的相关节律变化, Cz位于大脑中央部位, 作为参考电极。信号采样率为128 Hz, 进行0.5~30.0 Hz带通滤波。

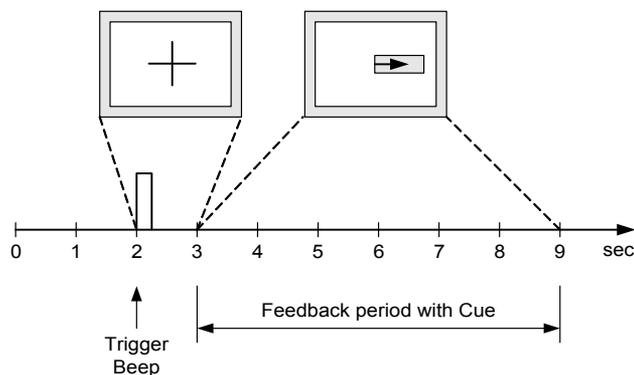


图1 实验时序示意图

Fig.1 Experimental sequence diagram

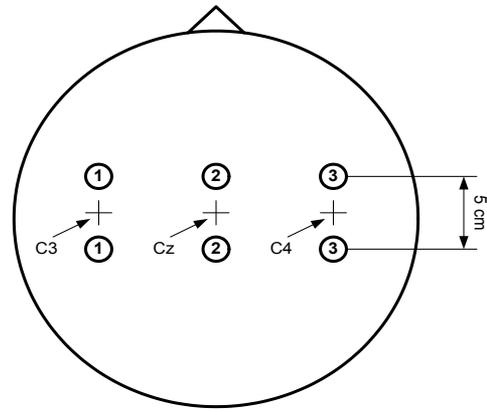


图2 电极放置位置

Fig.2 Position of electrodes

2 特征提取方法

本研究采用的特征提取方法是提取3种特征值后进行多特征融合, 可以更好突出EEG特征信息。下面将特征提取各部分算法的实现分别介绍。

2.1 EMD

EMD是一种针对非线性、非平稳信号的时频分析方法, EEG正是这种信号。与同为时频分析的小波变换相比, 它不需要选取基函数与分解层数, 具有自适应性^[5]。它从信号时间尺度特征出发, 进行平稳化处理, 将原始信号分解成一系列不同尺度的单一分量, 即IMF^[6-7]。IMF应满足两个条件: (1)在整个序列中极值点数量与过零点数量须相等或至多相差一个; (2)在任意时间点上、下包络线均值为零, 即信号关于时间轴局部对称^[8]。

EMD对脑电信号时间序列 $x(t)$ 的处理步骤如下:

(1)确定 $x(t)$ 的所有局部极值点, 用三次样条插值函数进行拟合, 由局部极大值和极小值点分别形成 $x(t)$ 的上包络线 $m_+(t)$ 和下包络线 $m_-(t)$, 并计算两包络线的均值为:

$$\bar{m}(t) = \frac{m_+(t) + m_-(t)}{2} \quad (1)$$

(2)用 $x(t)$ 减去均值 $\bar{m}(t)$, 得到的差值即信号分量 $h_1(t)$ 。判断 $h_1(t)$ 是否满足IMF的两个条件, 若满足, 则 $h_1(t)$ 可作为第一阶IMF分量 $c_1(t)$; 若不满足, 则以 $h_1(t)$ 代替 $x(t)$ 重复上述步骤, 直至满足条件为止, 获得 $c_1(t)$ 。

(3)计算 $x(t)$ 减去 $c_1(t)$ 后的残差 $r_1(t)$, 将 $r_1(t)$ 作为新序列, 重复步骤(1)和步骤(2), 可依次得到第二阶、第三阶IMF分量等, 即 $c_2(t), c_3(t), \dots, c_n(t)$, 直至 $r_n(t)$ 为单调函数且无法继续从中提取分量, 分解则结束。此时, 可将 $x(t)$ 表示为所有IMF分量和残差之

和,即:

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \tag{2}$$

其中, n 为得到的 IMF 个数。

EEG 信号被分解成一系列 IMF 后,突出了不同时间尺度的局部特征,且随阶数增大所代表的频率逐渐降低。一般分解 EEG 后的 IMF 数目为 5~8 个^[9],但并非所有都包含重要信息,只需选择部分 IMF 即可。

2.2 CSP

CSP 主要针对二分类问题,非常适合左右手运动想象的特征构造,其基本原理是对两个协方差矩阵同时对角化,并提取两种任务的空间成分,构建两类空间滤波器,使两类差异最大化^[10]。实现步骤如下:

(1) 分别计算两类信号的协方差矩阵:

$$C_i = \frac{E_i E_i^T}{\text{trace}(E_i E_i^T)} \tag{3}$$

其中, E_i 表示想象左手和右手的数据矩阵, $\text{trace}(E_i E_i^T)$ 为迹,表示矩阵对角线元素之和。

(2) 计算每一类的平均协方差矩阵 \bar{C}_i ,以构成混合空间的复合协方差矩阵。两类平均协方差矩阵之和为:

$$\bar{C} = \bar{C}_1 + \bar{C}_2 \tag{4}$$

(3) 对 \bar{C} 进行特征值分解,即 $\bar{C} = U \lambda U^T$,其中 λ 为特征值对角矩阵, U 为对应的特征向量矩阵。

(4) 进行白化处理,构建白化矩阵 P :

$$P = \lambda^{-\frac{1}{2}} U^T \tag{5}$$

利用 P 使 C_i 变成如下形式:

$$S_1 = P \bar{C}_1 P^T, S_2 = P \bar{C}_2 P^T \tag{6}$$

(5) 由于 S_1 和 S_2 具有相同特征向量,再次特征值分解,得到:

$$S_1 = B \lambda_1 B^T, S_2 = B \lambda_2 B^T \tag{7}$$

其中, B 为两者共同的特征向量,且 $\lambda_1 + \lambda_2 = I$ (I 为单位矩阵),也就是当其中一类特征值最大时,另一类特征值必为最小。

(6) 按照特征值大小将对应特征向量从大到小排序,取前 m 个特征向量组成矩阵 B_1 ,其余为 B_2 ,则构成一对空间滤波器 $W = [W_1, W_2]$,分别为:

$$W_1 = (B_1^T P)^T, W_2 = (B_2^T P)^T \tag{8}$$

利用它对 EEG 矩阵 E_i 滤波,则 E_i 被变换为 $Z_i = W_i \times E_i$ 。

(7) 将 Z_i 作如下运算作为特征值:

$$f_p = \log \left[\frac{\text{var}(Z_p)}{\sum_{i=1}^{2m} \text{var}(Z_i)} \right] \tag{9}$$

其中, $p = 1, 2, \dots, 2m(2m < n)$ 。将所有 f_p 构成最终特征值矩阵 $F = \{f_1, f_2, \dots, f_{2m}\}$,即为一组脑电特征^[11-12]。

2.3 AR 模型

AR 模型属于时域分析,基本思想是:假设可用自回归过程近似于真实的 EEG,从而可用较少的参数反映较多谱信息^[13]。基于此假设,选取合适的阶次和参数,可使 AR 过程最大程度逼近 EEG。AR 模型的参数辨识简单,实时性较好,因此 AR 系数作为脑电特征量非常合适^[14]。

对于一般随机信号,AR 模型可以表示为如下形式:

$$y(n) = -\sum_{i=1}^p a_i y(n-i) + r(n) \tag{10}$$

其中, $y(n)$ 是信号的第 n 个采样值, p 是模型阶数, $\{a_i\}$ 是模型系数, $r(n)$ 为零均值白噪声的残差。本研究运用 Burg 算法进行系数估计,主要原理如下:

令 $e_p(n)$ 和 $b_p(n)$ 分别为 AR 模型的前向和后向预测误差, P_e 和 P_b 分别为它们的功率,具体表达式这里不进行赘述。令两功率之和为:

$$P_{eb} = \frac{1}{2}(P_e + P_b) \tag{11}$$

当阶数 $i = 1 \sim p$ 时, $e_i(n)$ 与 $b_i(n)$ 有如下递推关系:

$$e_i(n) = e_{i-1}(n) + k_i b_{i-1}(n-1) \tag{12}$$

$$b_i(n) = b_{i-1}(n-1) + k_i e_{i-1}(n) \tag{13}$$

其中, $e_0(n) = b_0(n) = y(n)$, k_i 为反射系数, $k_i = a_{ii}$ 。

Burg 算法的目的是使 P_{eb} 相对于 k_i 最小。系数 a_i 则可由 Levinson-Durbin 递推算法求出:

$$a_{ij} = \begin{cases} a_{i-1,j} + k_i a_{i-1,i-j}, & j = 1, 2, \dots, i \\ k_i, & j = i \end{cases} \tag{14}$$

选择阶数是影响 AR 系数特征的关键,本研究选择的阶数为 6。

2.4 基于 PCA 的特征降维

上述 3 种算法得到的特征向量组合后维数较高,不利于分类器识别,使算法不够准确快速,因此选择 PCA 算法实现降维。PCA 根据方差最大化原理,用一组线性无关且相互正交的新向量来对原向量进行表征,这组新向量即主成分,是原来向量的线性组合^[9]。实现步骤如下^[15-16]:

(1) 设原始特征集为 $\{x_1, x_2, \dots, x_n\}$, 先进行去均值处理,得到中心化后的矩阵:

$$X = x_i - \frac{1}{n} \sum_{i=1}^n x_i \tag{15}$$

(2) 计算 X 的协方差矩阵 $C, C = X X^T$ 。对 C 特征值分解, $C = U \lambda U^T$, 得到特征值 λ 和特征向量 U , λ 为对角阵,表示主成分方差的大小。

(3) 将 λ 排序: $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d$, 取前 d' 个特征

值对应的特征向量构成投影矩阵 $W=(u_1, u_2, \dots, u_{d'})$ 。其中, d' 为降维后的维数, 由各成分的累积贡献率决定, 即:

$$C_{rate} = \frac{\sum_{j=1}^{d'} \lambda_j}{\sum_{i=1}^d \lambda_i} \quad (16)$$

一般 $C_{rate} \geq 85\%$ 即可。

(4) 根据 W 求出低维空间的新特征量 $F=X*W$ 。

经 PCA 处理后的新特征最大程度代表了有用信息, 剔除对应于 $d-d'$ 个特征值的那些特征向量, 使样本采样密度增大, 一定程度起到去噪作用^[16], 作为下一步分类器的输入更佳。

3 数据处理及结果

3.1 预处理

为了使数据尽可能去除其他因素的影响, 具有代

表性, 首先对原始 EEG 信号预处理。Cz 电极一般作为参考电极, 故本研究只选取 C3 和 C4 通道, 图 3 为某次样本 C3 和 C4 通道原始信号。研究表明, 人们在实施或仅是想象单侧手运动时, 其对侧运动感觉区的 μ 节律 (8~13 Hz) 和 β 节律 (18~30 Hz) 会出现幅值降低的现象, 称为事件相关去同步 (Event-Related Desynchronization, ERD); 其同侧运动感觉区的 μ 节律和 β 节律出现幅值升高的现象, 称为事件相关同步 (Event-Related Synchronization, ERS)^[17]。因此滤除噪声及非相关的大脑活动频段, 使信号更好体现运动想象特征。本研究选择 FIR 等波纹滤波器对包含 140 次信号的样本进行 8~30 Hz 带通滤波, 滤波器参数设置为: 通带截止频率分别为 8 和 30 Hz, 阻带截止频率分别为 6 和 32 Hz, 通带衰减为 1 dB, 阻带衰减为 50 dB, 密度因子为 20。图 4 为滤波后的 C3 和 C4 通道信号, 滤波后的 EEG 较好地消除噪声信号及无关思维信号的影响。

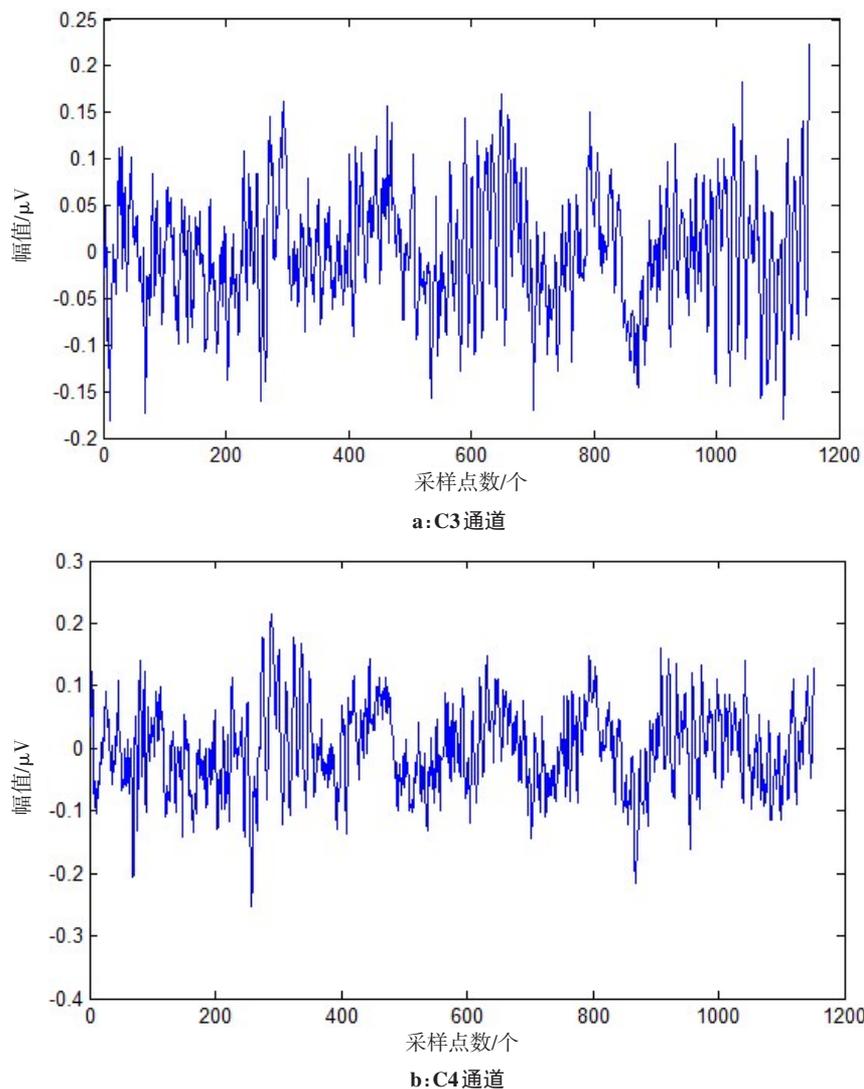


图3 原始 EEG 信号

Fig.3 Original electroencephalogram (EEG) signals

由于数据采集过程中,第3秒才给予运动想象提示,且受试者有一定反应时间。且在图4中,该组信号对应类别号为1,即左手运动想象,可看出在第500个采样点后,与左手同侧的C3通道幅值增大,对侧的C4通道幅值则较小,体现了一定的ERS/ERD现象。

因此本研究经过对比后,选取9 s数据中的4~8 s作为使用。数据采样率为128 Hz,单次实验时长9 s,则每次实验中每通道有1 152个点,故应截取其中的第512~1 023个点。此时数据为512×2×140,其中,512为采样点数,2为通道数,140为实验次数。

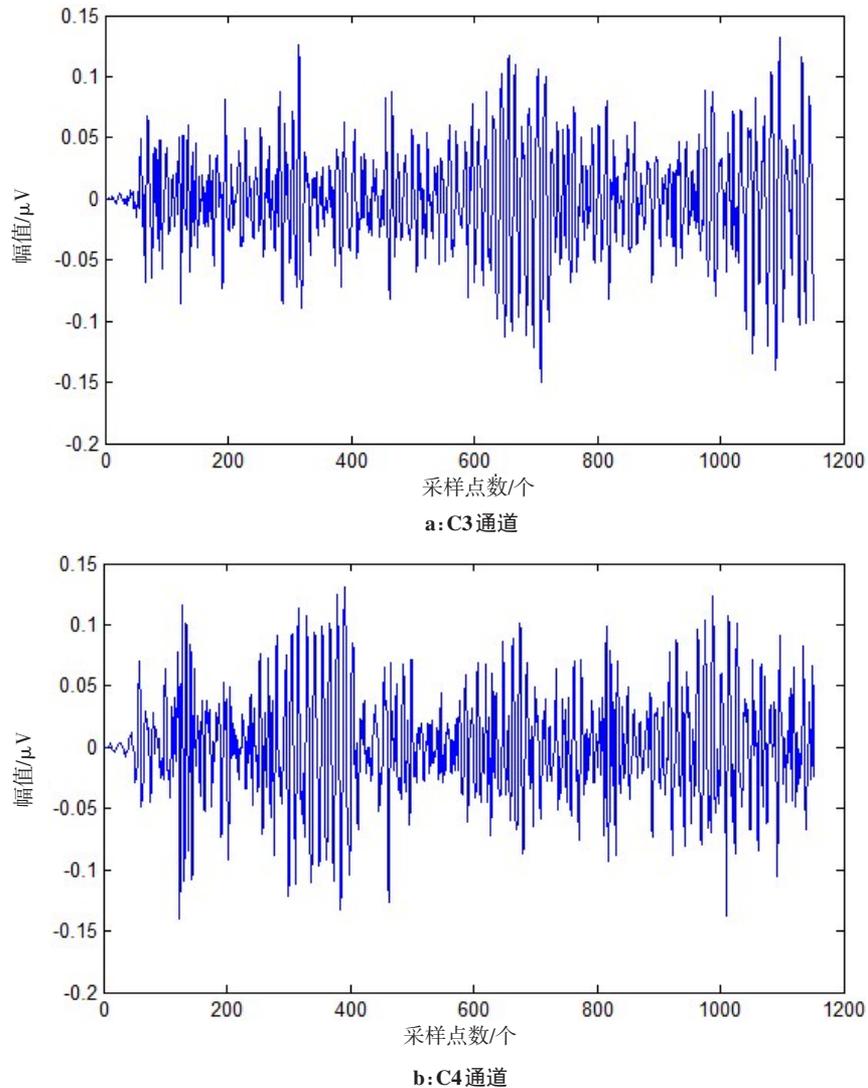


图4 滤波后的EEG信号
Fig.4 Filtered EEG signals

3.2 特征提取与融合

(1)采用EMD对预处理后的EEG信号分解,得到一系列IMF。由于EMD是一种自适应分解方法,因此无须提前确定分解阶数。图5和图6分别是C3和C4通道信号的IMF波形。

如图5和图6所示,信号被自适应地分解为imf1~imf6共6阶IMF和残差(res),残差表示最终的信号趋势情况。从图中可以看出,C3和C4的趋势相反。在6阶IMF中,随着信号分解,频率不断降低,有用信息逐渐减少,因此仅选取能量最为集中的前三阶IMF进行特征值提取。由于ERS/ERD现象,C3和

C4通道的能量有所差别,故使用能量值作为特征。能量的计算公式为^[18]:

$$E_{j,k} = \sum_{i=1}^n [c(i)]^2 \tag{17}$$

其中, $E_{j,k}$ 为第j个通道第k个IMF分量的能量, $c(i)$ 是IMF的第i个值, n 为长度。每次样本可得到6维能量特征向量: $F_1 = \{E_{1,1}, E_{1,2}, E_{1,3}, E_{2,1}, E_{2,2}, E_{2,3}\}$ 。

(2)使用CSP提取空域特征值,它实质上是构造一组空间滤波器。对于二分类,可得到一对空间滤波器,则特征值为2维,即每次样本得到的特征向量为: $F_2 = \{f_1, f_2\}$ 。

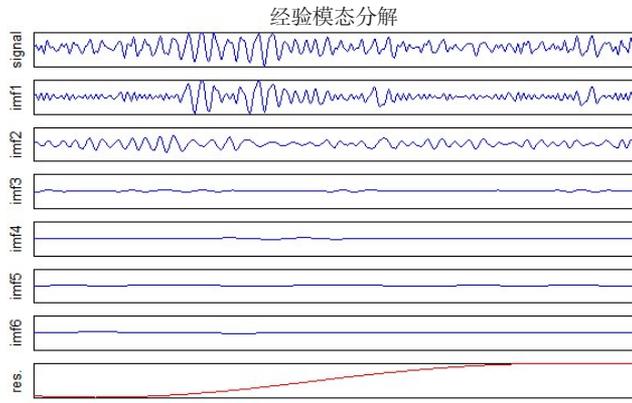


图5 C3通道的各阶IMF

Fig.5 Each order intrinsic mode functions (IMF) of channel C3

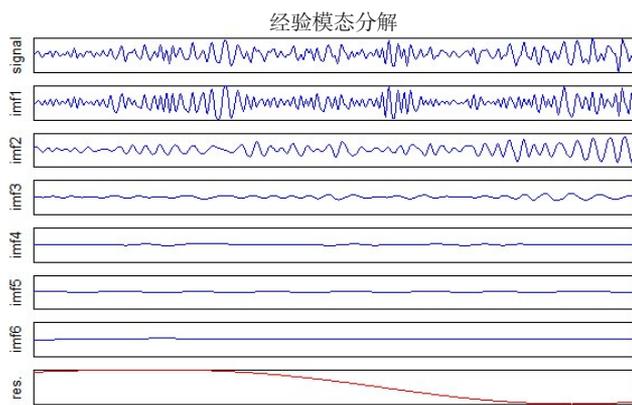


图6 C4通道的各阶IMF

Fig.6 Each order IMF of channel C4

(3)用AR系数作为时域特征,本研究基于Burg算法进行模型系数估计,经过对比后确定阶数为6,则可相应得到6个系数。对每次样本的C3和C4通道分别提取6个AR系数后,共可得到12维特征向量 $F_3 = \{a_1, a_2, a_3, \dots, a_{12}\}$,其中, $a_1 \sim a_6$ 为C3通道的AR系数, $a_7 \sim a_{12}$ 为C4通道的AR系数。

经过3种算法对EEG进行特征提取后,将每种特征向量进行合并,共可得到20维时-频-空特征向量 $F = F_1 + F_2 + F_3 = \{E_{1,1}, E_{1,2}, E_{1,3}, E_{2,1}, E_{2,2}, E_{2,3}, f_1, f_2, a_1, a_2, a_3, \dots, a_{12}\}$,由于高维特征向量不利于分类器识别,且每种特征的重要程度不同,即对运动想象EEG分类的贡献率不同,用PCA降维以保留累积贡献率大于85%的主成分特征,得到6维的主成分特征向量 F' 。此时的特征向量 F' 最大程度体现了脑电特征,不仅减少了分类器的输入量,同时去除了贡献程度小的冗余信息,更加利于识别。

3.3 基于SVM的分类识别

基于统计学习理论的SVM是一种监督学习方法,对非线性、小样本及高维数据可取得理想的分类效果^[19],基本思想是找到一个最优分类超平面,使它尽可能将

两类样本点分开,且使间隔最大化^[20]。本研究的SVM分类模型为C-SVC,经过对比后,选择RBF核函数。此外要确定SVM中的两个参数,惩罚因子C和核参数 γ 。本研究采用网格搜索法进行参数寻优,找到最佳的C和 γ 组合,分别以C和 γ 的取值范围作为网格边长,用合适的步进值交叉成一系列网格,则每个交叉点就是一组C和 γ 值,通过对这些点进行搜索,计算每一处的分类准确率,以找到使准确率最高时的C和 γ 值。在 $[0, 1]$ 内对特征向量归一化处理,首先粗略优化,在较大范围的搜索后将范围设置小一些,再精细优化,设置惩罚因子 $C_{min} = -4, C_{max} = 4$,核参数 $g_{min} = -4, g_{max} = 4$,步进值 C_{step} 和 g_{step} 均为0.5。得到如图7所示的参数选择结果等高线图,可看出在不同的C和g组合时的准确率。得到 $C_{best} = 1.414 2, g_{best} = 0.707 1$,由于程序在实现时搜索的值为2的指数,即 $\log_2 c$ 和 $\log_2 g$,即实际C的最优值为 $2^{1.414 2}, \gamma$ 的最优值为 $2^{0.707 1}$,此时的最大分类准确率为91.9%。

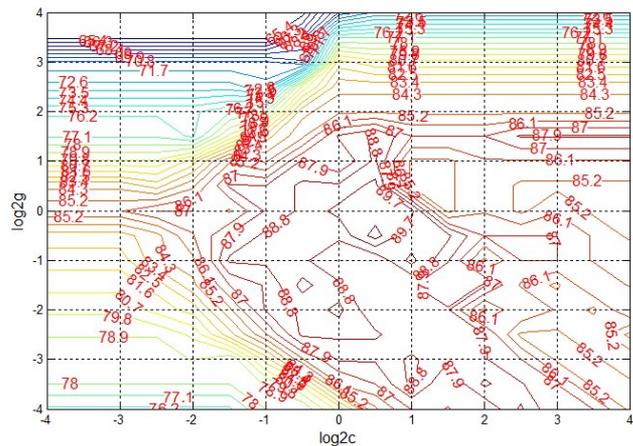


图7 SVM参数选择结果图(等高线图)

Fig.7 Support vector machine (SVM) parameter selection result (contour map)

3.4 结果对比分析

为验证本研究算法的有效性,做了两组对比实验。第一组是与单一特征及两两特征结合时的识别率对比,均使用SVM识别,得到如表1所示的结果。如表1所示,使用单一特征值时,CSP的识别率最高,EMD的识别率最低;在特征两两结合时,识别率均大于80%,较单一特征有所提高,其中,CSP和AR模型结合时的识别率最高,同时由于单一特征时CSP效果最好,在两两结合时,与CSP结合的两种算法较另一种都更高;而本研究采用的多特征融合方法,达到91.9%的准确率,明显高于其他6种,证明本研究特征提取算法的有效性。

表1 不同特征下的SVM识别率对比

Tab.1 Comparison of SVM recognition rate based on different features

特征提取方法	识别率/%
EMD	75.3
CSP	82.5
AR模型	78.6
EMD+CSP	84.7
EMD+AR模型	81.2
CSP+AR模型	85.6
本研究的特征融合	91.9

第二组对比是将本研究的特征用另外两种分类器识别。选择BP神经网络和概率神经网络概率神经网络进行对比,均使用本研究特征作为输入,BP神经网络、概率神经网络和SVM识别率分别为85.4%、83.6%、91.9%,BP神经网络和PNN的识别率均低于本研究通过参数寻优后的SVM,证明本研究SVM分类的有效性和可行性,说明将其与本研究的融合特征结合是相对匹配的。

4 结论

本研究对BCI2003数据预处理后分别使用EMD、CSP、AR模型3种算法,得到时-频-空特征向量,用PCA降维后,用SVM分类,得到91.9%的识别率。同时做了两组对比实验,证明本研究多特征融合及SVM分类的有效性。运动想象脑电信号的识别作为BCI的关键环节,对BCI的功能准确度起到重要作用,而特征值的表征能力与脑电识别率密切相关。本研究的特征提取方法较以往单一特征得到较好的效果,可用于BCI对高识别率的要求。此外该算法可继续研究运动想象多分类,增加算法普适性。

【参考文献】

[1] GAUR P, PACHORI R B, WANG H, et al. An empirical mode decomposition based filtering method for classification of motor-imagery EEG signals for enhancing brain-computer interface[C]// International Joint Conference on Neural Networks. IEEE, 2015.

[2] PENG L, YUAN D, LOU Y, et al. Single-trial identification of motor imagery EEG based on HHT and SVM[C]// Proceedings of 2013 Chinese Intelligent Automation Conference. 2013.

[3] 金海龙, 张志慧. 基于希尔伯特-黄变换和BP神经网络的运动想象脑电研究[J]. 生物医学工程杂志, 2013, 30(2): 249-253.

JIN H L, ZHANG Z H. Research of movement imagery EEG based on Hilbert-Huang transform and BP neural network[J]. Journal of Biomedical Engineering, 2013, 30(2): 249-253.

[4] CHATTERJEE R, BANDYOPADHYAY T. EEG based motor imagery classification using SVM and MLP[C]//International Conference on Computational Intelligence and Networks. IEEE, 2016: 84-89.

[5] 叶林, 刘鹏. 基于经验模态分解和支持向量机的短期风电功率组合

预测模型[J]. 中国电机工程学报, 2011, 31(31): 102-108.

YE L, LIU P. Combined model based on EMD-SVM for short-term wind power prediction[J]. Proceedings of the CSEE, 2011, 31(31): 102-108.

[6] 郝凤龙, 徐更光, 黄学义. 基于经验模态分解及小波变换的炸药NQR信号处理[J]. 振动与冲击, 2014, 33(16): 183-187.

HAO F L, XU G G, HUANG X Y. Processing of explosive nuclear quadrupole resonance signals based on empirical mode decomposition and wavelet transform[J]. Journal of Vibration and Shock, 2014, 33(16): 183-187.

[7] 王银辉. 基于EMD和混合特征的癫痫脑电信号识别研究[D]. 大连: 大连理工大学, 2016.

WANG Y H. The research of epileptic EEG signals identification based on EMD and mixed features[D]. Dalian: Dalian University of Technology, 2016.

[8] HUANG N E, WU M L, LONG S R, et al. A confidence limit for the empirical mode decomposition and Hilbert spectral analysis[J]. Proc Math Phys Eng Sci, 2003, 459(2037): 2317-2345.

[9] 关俊强, 杨帮华, 马世伟, 等. 基于PCA及SVM的运动想象脑电信号识别研究[J]. 北京生物医学工程, 2010, 29(3): 261-265.

GUAN J Q, YANG B H, MA S W, et al. Classification of motor imagery EEG based on PCA and SVM [J]. Beijing Biomedical Engineering, 2010, 29(3): 261-265.

[10] FALZON O, CAMILLERI K P, MUSCAT J. The analytic common spatial patterns method for EEG-based BCI data[J]. J Neural Eng, 2012, 9(4): 045009.

[11] 张焕, 乔晓艳, 王飞. 基于小波-共空间模式的多类想象运动诱发脑电特征提取[J]. 测试技术学报, 2015, 29(6): 523-528.

ZHANG H, QIAO X Y, WANG F. The feature extraction for EEG signal evoked by multi classification motor imagery based on wavelet-common spatial pattern analysis [J]. Journal of Test and Measurement Technology, 2015, 29(6): 523-528.

[12] YANG B H, WU T, WANG Q, et al. Motor imagery EEG recognition based on WPD-CSP and KF-SVM in brain computer interfaces[J]. Appl Mech Mater, 2014, 556-562: 2829-2833.

[13] 李昕, 孙小棋, 王欣, 等. 基于自回归小波包熵特征融合算法的情感识别研究[J]. 生物医学工程杂志, 2017, 34(6): 831-836.

LI X, SUN X Q, WANG X, et al. Research on electroencephalogram emotion recognition based on the feature fusion algorithm of auto regressive model and wavelet packet entropy [J]. Journal of Biomedical Engineering, 2017, 34(6): 831-836.

[14] 邹清. 基于AR模型的脑电信号特征提取与识别[D]. 长沙: 中南大学, 2008.

ZOU Q. Feature extraction and recognition of EEG based on AR model [D]. Changsha: Central South University, 2008.

[15] 李昕, 蔡二娟, 田彦秀, 等. 一种改进脑电特征提取算法及其在情感识别中的应用[J]. 生物医学工程杂志, 2017, 34(4): 510-517.

LI X, CAI E J, TIAN Y X, et al. An improved electroencephalogram feature extraction algorithm and its application in emotion recognition [J]. Journal of Biomedical Engineering, 2017, 34(4): 510-517.

[16] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016.

ZHOU Z H. Machine learning [M]. Beijing: Tsinghua University Press, 2016.

[17] ROSSO O A, MARTIN M T, FIGLIOLA A, et al. EEG analysis using wavelet-based information tools[J]. J Neurosci Methods, 2006, 153(2): 163-182.

[18] 杨航, 郭晓金. 基于EMD的运动想象脑电特征提取与识别[J]. 软件导刊, 2015, 14(1): 44-47.

YANG H, GUO X J. Feature extraction and recognition of motor imagery EEG based on EMD[J]. Software Guide, 2015, 14(1): 44-47.

[19] 李明爱, 刘净瑜, 郝冬梅. 基于改进CSP算法的运动想象脑电信号识别方法[J]. 中国生物医学工程学报, 2009, 28(2): 161-165.

LI MA, LIU J Y, HAO D M. EEG recognition of motor imagery based on improved CSP algorithm [J]. Chinese Journal of Biomedical Engineering, 2009, 28(2): 161-165.

[20] CORTES C, VAPNIK V. Support-vector networks[J]. Mach Learn, 1995, 20(3): 273-297.

(编辑:陈丽霞)