

基于小波包基与能量熵的 MEG 自动分类方法

张学军^{1,2}, 丁钰涵¹, 黄丽亚^{1,2}, 成谢锋^{1,2}

(1. 南京邮电大学 电子科学与工程学院, 江苏 南京 210003;

2. 江苏省射频集成与微组装工程实验室, 江苏 南京 210003)

摘要: 脑磁信号中包含许多与精神疾病相关的生理信息, 是判断神经系统出现各种异常活动的重要依据, 对脑科学的研究具有十分重要的意义。为了提高正常人与精神分裂症患者的 MEG 数据的分类精度, 文中提出了一种基于小波包基与能量熵的脑磁特征提取与识别的方法。该方法首先将经 PCA 降维后的 MEG 数据进行小波包分解, 并结合小波熵从小波包库中选择最优小波包基, 然后对选出的最优基所对应的小波系数进行幅度调制求取能量熵, 并求取包络能量熵的统计特性构成分类特征向量, 最后输入到 SVM 分类器, 实现 MEG 数据的自动分类。实验结果表明, 该方法的分类准确度可达到 97.586 8%。说明文中提出的特征提取方法能够有效提取脑磁信号的特征, 提高分类精度; 也将为精神分裂症的诊断和严重程度评估提供选择依据。

关键词: 脑磁信号; 小波包分解; 幅度调制; 能量熵; 支持向量机

中图分类号: R318

文献标识码: A

文章编号: 1673-629X(2016)06-0127-06

doi: 10.3969/j.issn.1673-629X.2016.06.028

Automatic Classification Method of MEG Based on Wavelet Packet and Energy Entropy

ZHANG Xue-jun^{1,2}, DING Yu-han¹, HUANG Li-ya^{1,2}, CHENG Xie-feng^{1,2}

(1. School of Electronic Science and Engineering, Nanjing University of Posts and Telecommunications,
Nanjing 210003, China;

2. Jiangsu Province Engineering Lab of RF Integration & Micropackage, Nanjing 210003, China)

Abstract: MEG signals associated with many physiological information related to mental illness is an important basis for judging abnormal nervous system activity and has great significance for the study of brain science. In order to improve accuracy of normal and schizophrenia's MEG signals, a new method of MEG classification with feature extraction is proposed based on wavelet packet and energy entropy. First, it reduces the dimension of the raw signals by Principal Component Analysis (PCA) and decomposes preprocessed signal by Wavelet Packet Decomposition (WPD). Then, selects the best basis of wavelet packets from a wavelet packet library according to the wavelet packet entropy, afterwards calculating the energy entropy of envelope that acquired by Amplitude Modulation (AM) of the best basis wavelet coefficients. Moreover, the eigenvector is obtained by calculating the statistical features of energy entropy. Finally, the feature vectors are put into a Support Vector Machine (SVM) to realize automatic classification of MEG. Experiment shows that the proposed method could achieve a great classification accuracy of 97.586 8%, which indicates that the feature extraction method in this paper can effectively extract the characteristic of MEG and improve the classification accuracy. It provides evidence for the treatment and severity assessment of schizophrenia.

Key words: MEG; wavelet packet decomposition; amplitude modulation; energy entropy; support vector machine

0 引言

脑磁图 (Magnetoencephalography, MEG) 是一种无创伤地探测大脑电磁生理信号的脑功能检测技术, 在

进行脑检查时探测器不需要固定于患者头部, 检测设备对人体无任何副作用。与脑电图反映脑的电场变化不同, MEG 反映的是脑的磁场变化。脑磁图不受颅骨

收稿日期: 2015-08-25

修回日期: 2015-12-03

网络出版时间: 2016-06-00

基金项目: 国家自然科学基金资助项目 (61271334)

作者简介: 张学军 (1969-), 男, 博士, 教授, 研究方向为智能信息处理、认知网络频谱感知、无线射频识别技术等; 丁钰涵 (1992-), 女, 硕士研究生, 研究方向为智能信息处理。

网络出版地址:

的影响,图像清晰易辨,加之对脑部损伤的定位诊断比脑电图更为准确,故对脑部疾病的诊断发挥了其特有的作用。

特征提取是对脑信号进行识别的关键技术之一。在对不同脑信号进行识别时,如果提取的信号特征显著就能获得较高的分类精度。目前常用的特征提取方法有时域、频域和时频域结合的分析方法^[1-8]。与单一的时域或频域分析方法相比,时频域结合的分析方法能够提供更多的分类信息,因此人们常把时频域结合的分析方法用于生理信号的特征提取中。文献[2]提出了混沌分析和小波包变换相结合的特征提取方法。文献[3]采用基于互信息的特征提取方法。文献[5]将样本熵(或近似熵)应用到具有短序列特性的生理信号分析中,实现对生理信号的时频分析。

将熵与小波包变换结合是目前常用的分析生理电信号的特征提取方法。王登等^[9]使用小波包分解与小波包熵结合的特征提取方法对五类不同脑思维任务进行分类的平均分类准确率高于传统的小波包分解算法。王攀等^[10]将小波变换与时域能量熵结合,发现该特征提取方法有较好的分类效果及较短的分类系统运算时间。

在 MEG 信号的特征分类中获得稳定的神经网络是非常困难的,因为其通常需要选择合适的隐藏层和神经元数目来逼近解决问题的函数所需要的精度。如果网络中样本的数目太多会导致训练数据的过度拟合,进一步导致泛化能力下降。支持向量机(Support Vector Machine, SVM)不仅有稳定的统计学习理论,同时保证训练数据有最优的决策函数^[11]。它的优点在于通过最大化网络的性能以及降低学习机的复杂度来平衡准确度。现有的方法在特征提取部分都是对小波包变换或者小波变换后的系数直接求取能量熵或者 AM 调制作为特征^[12]。

文中提出基于小波包基与能量熵的脑磁特征提取方法,将经主成分分解(PCA)法降维后的 MEG 数据进行小波包分解,结合小波熵概念从小波包库中选择最优小波包基,接着对最优基所对应的小波系数进行幅度调制求取能量熵,将能量熵的最大值、最小值、均值、方差构成特征向量作为 SVM 的输入,实现 MEG 信号的自动分类。

1 脑磁信号特征提取

1.1 最优小波包基

小波包分解(Wavelet Packet Decomposition, WPD)能够为信号提供更精细的分析方法。它将频带进行多层次划分,将多分辨率分析没有细分的高频部分进一步分解,并能够根据被分析信号的特征,自适应地选择

相应频带,使之与信号频谱相匹配,从而提高了时频分辨率。

小波包变换的双尺度方程为:

$$\begin{cases} u_{2n}(t) = \sqrt{2} \sum_{k \in Z} h(k) u_n(2t - k) \\ u_{2n+1}(t) = \sqrt{2} \sum_{k \in Z} g(k) u_n(2t - k) \end{cases} \quad (1)$$

其中, $h(k)$, $g(k)$ 是多分辨分析中的滤波器系数。

当 $n = 0$ 时, $u_0(t)$ 和 $u_1(t)$ 分别退化为尺度函数 $\Phi(t)$ 和小波基函数 $\Psi(t)$ 。定义由式(1)构造的序列 $\{u_n(t)\} (n \in Z_+)$ 为由基函数 $u_0(t) = \Phi(t)$ 确定的小波包。

小波包系数的递推公式为:

$$\begin{cases} v_k^{j+1, 2n} = \sum_l h_{2l-k} v_l^{j,n} \\ v_k^{j+1, 2n+1} = \sum_l g_{2l-k} v_l^{j,n} \end{cases} \quad (2)$$

在小波包分解中,对于给定的小波,长度为 $M = 2^N$ 的信号可以分解为深度为 N 的完整二叉树。通常一棵完整的二叉树的子树数目较大,且并非所有的子树都有价值,所以就有了最佳小波包基的选择问题。1992 年,Coifman 等^[13]提出了最佳基选择准则用于解决最优树的选择问题。该准则是在不改变二叉树为分解结构的基础上加入熵作为下一步分解的准则,具体是当一个节点对应的子空间中的小波包熵大于其下一级子节点对应的两个子空间的小波包熵之和时才继续划分,否则停止划分。小波包熵有五种常用的标准,即:香农(Shannon)熵、阈值熵、范数(norm)熵、对数能量(log energy)熵、SURE 熵^[14]。文中使用对数能量熵,其定义为:

$$E(S) = \log(S_i^2) \quad (\text{约定 } E(0) = 0) \quad (3)$$

式中, 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。

1.2 幅度调制与能量熵

基于 Hilbert 变换的幅度调制方法(AM)能够准确地获得信号在采样频率上的包络,以及量化事件相关去同步化(Event-Related Desynchronization, ERD)^[15]的活动。文献[10]将幅度调制与离散小波变换(Discrete Wavelet Transform, DWT)结合用于提取 EEG 的包络特征,对左手移动和静息状态的单务脑电信号的平均分类准确率为 84.4%。基于 Hilbert 变换的幅度调制公式为:

$$AS_i(k) = \sqrt{S_i(k)^2 + H(S_i(k))^2} \quad (4)$$

式中, $H(x)$ 为对 MEG 信号 x 的 Hilbert 变换; S_i 为最优小波基的节点系数。

另外,相比于通道数较少的脑电信号,全头型脑磁图设备记录的脑磁信号的通道数较多。为了提高分类精度并减少特征提取的计算量,文中在对小波包系数进行幅度调制后计算调制包络的能量熵,对小波包系数幅度调制后计算能量熵可以表征信号复杂度在时域的变化情况,也可以表征信号的频域特征,具有良好的时域局部化能力^[16]。由香农熵的定义^[17],时域能量熵可表示为:

$$E_i = -\log_2\left(\frac{P_i}{P}\right) \quad (5)$$

式中, $\sum_{i=1}^n P_i = P$; E_i 为第 i 段信号的时域能量熵; P_i 为第 i 段信号的能量; P 为信号的总能量; n 为信号分割的段数。

由式(5)可知:当时域能量在信号总能量中的比重大时,能量熵小;当时域能量在信号总能量中的比重小时,能量熵大。

1.3 基于小波包基与能量熵的特征提取方法

小波包分解将频带进行多层次划分,对多分辨率分析没有细分的高频部分进一步分解,自适应地选择相应频带,使之与信号频谱相匹配,从而提高了时频分辨率;基于 Hilbert 变换的幅度调制方法能够准确地获得信号在采样频率上的包络,以及量化事件相关去同步化的活动;而能量熵可以表征信号复杂度在时域的变化情况,也可以表征信号的诸多频域特征,具有良好的时域局部化能力。

文中结合小波包分解和能量熵的优点,提出了基于小波包基与能量熵的脑磁信号特征提取方法。利用该方法提取的特征值区分正常人和精神病分裂症患者的脑磁信号的分类精度可达 97.586 8%。算法步骤为:

步骤 1:选用小波包函数对预处理后的每一段脑磁数据进行小波包分解,得到完全分解树。

步骤 2:对树中的每个节点 $N_{i,j}$ 按照式(3)计算第 i 层的第 j 个节点的小波包熵 $E_{i,j}$,运用最小小波熵的原则求取最优小波包基树。

步骤 3:对最优小波包基树中的每一个节点按照式(2)求取其小波包系数,并对求取的每一个小波包系数按照式(4)进行 AM 调制。

步骤 4:将 AM 调制后的数据分割成 n 段,按照式(5)求取能量熵。为了进一步降低特征维数,对每一组小波包系数对应的能量熵求取最大值、最小值、均值和方差等统计特性,作为提取的特征值。

将提取的每段 MEG 信号的特征值组成该组信号的特征向量,用该特征向量训练 SVM 分类器,从而实现对正常人和精神分裂症患者的 MEG 信号的分类。

1.4 SVM 分类器

支持向量机是 Cortes 等^[18]于 1995 年首先提出的,它在解决小样本、非线性及高维模式识别中表现出许多特有的优势,并能够推广应用到函数拟合等其他机器学习问题中。SVM 方法是建立在统计学习理论的 VC 维理论和结构风险最小原理基础上的,通过构造一个超平面作为决策面将两类样本尽量正确分开且分离的两类间隙最大化,若样本是非线性的,可以映射到高维变为线性的,然后再进行分类。它的优点在于通过最大化网络的性能以及降低学习机的复杂度来平衡准确度。

对于一个训练样本 $W = \{(\mathbf{x}_i, d_i)\}_{i=1}^N$, \mathbf{x}_i 是输入向量, $d_i \in \{-1, 1\}$ 是类别标号, N 是数据分段总数,则 SVM 优化的问题是:

$$\min_w \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^N \xi_i \quad (6)$$

$$\text{且 } \xi_i \geq 0, d_i(\mathbf{w}^T \mathbf{x}_i + \mathbf{b}) \geq 1 - \xi_i, \forall i = 1, 2, \dots, N。$$

式中, $g(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + \mathbf{b}$ 代表了超平面; \mathbf{w} 为加权向量; \mathbf{b} 为偏置; \mathbf{x}_i 为标签 d_i 下的训练向量; C 为加权常数; ξ 为松弛变量。

通过选取最优的 \mathbf{w} 和 \mathbf{b} 得到判决函数:

$$g(\mathbf{x}) = \mathbf{w}_0^T \mathbf{x} + b_0 \quad (7)$$

进一步用核函数 $k(\mathbf{x}, \mathbf{x}_i)$ 代替点积,将原特征空间换到新的特征空间,相应的判别函数式变为:

$$g(\mathbf{x}) = \sum_{i=1}^N \alpha_i d_i K(\mathbf{x}, \mathbf{x}_i) + b_0 \quad (8)$$

式中, α_i 为支持向量系数; b_0 为分类阈值; $K(\mathbf{x}, \mathbf{x}_i)$ 为一个内核函数。

一般情况下, SVM 选择的内核函数有多项式核函数或径向基函数(RBF)核函数:

$$K(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i^T \mathbf{x}_j + 1)^p \quad (9)$$

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp((-1/2\sigma^2) \|\mathbf{x}_i - \mathbf{x}_j\|^2) \quad (10)$$

其中, σ 为宽度参数。

2 基于小波包基与能量熵的特征提取方法实验

2.1 数据和数据预处理

实验中使用的脑磁数据来源于美国 NIH(National Institute Mental Health)研究中心,脑磁数据采用具有 275 个通道的 CTF-275 脑磁测量仪采集^[19]。实验采集了 2 个类别共 18 位测试者的脑磁信号,其中包括 9 位正常人(Normal)、9 位精神分裂症病人(Patient)。测试者处于闭眼体静息状态,采样频率为 600 Hz,采集时间为 240 s。将采集到的 MEG 信号去除噪声和伪迹得到纯净的脑磁信号。为了减少计算量,实验中将数

据降频到 150 Hz,提取 26 s 到 46 s 的数据段进行分析,故每个数据样本都是一个 $275 \times 3\,000$ 的二维数据阵列。

在进行特征提取前,先对数据进行信号异常点更正、MEG 数据的降维以及 MEG 分段等预处理。首先进行异常点更正,将大于样本平均值 195% 的点或小于样本平均值 5% 的点分别用样本平均值 $\times 1.95$ 及样本平均值 $\times 0.05$ 替代。接着对多通道的 MEG 的数据运用 PCA 法对数据信息进行降维,去掉冗余信息,留下代表主要信息的分量,从而减少计算量^[20]。设 M 道原始数据构成一个 $M \times N$ 的数据阵 \boldsymbol{W} (N 表示每段数据的长度, $N > M$),令 $\boldsymbol{W}\boldsymbol{W}^{\text{T}} = \boldsymbol{V}(\boldsymbol{W}^{\text{T}}$ 为 \boldsymbol{W} 的转置), \boldsymbol{V} 为 \boldsymbol{W} 的协方差阵, \boldsymbol{V} 可作如下分解:

$$\boldsymbol{V}_{M \times M} = \boldsymbol{W}_{M \times N} \boldsymbol{W}_{N \times M}^{\text{T}} = \boldsymbol{U}_{M \times M} \boldsymbol{\Lambda}_{M \times M} \boldsymbol{U}_{M \times M}^{\text{T}} \quad (11)$$

式中, $\boldsymbol{\Lambda}$ 是对角阵, $\boldsymbol{\Lambda} = \text{diag}[\lambda_1 \lambda_2 \cdots \lambda_M]$, 且 $\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_M \geq 0$, λ_i 为 \boldsymbol{V} 的特征根; \boldsymbol{U} 为特征值相对应的特征向量组成的正交矩阵, 所以有:

$$\boldsymbol{P}_{M \times N} = \boldsymbol{U}_{M \times M}^{\text{T}} \boldsymbol{W}_{M \times N} \quad (12)$$

称 \boldsymbol{P} 的各行为 \boldsymbol{W} 的主成分,在 \boldsymbol{P} 中按能量大小排序,将其对应的特征值 $\lambda_i (i = 1 \sim M)$ 与特征值总和的比值 $\lambda_i / \sum_{i=1}^M \lambda_i$ 称为主成分分量的贡献率,表征该分量代表原始信号能量的百分比。文中以累计贡献率不小于 95% 来选取主成分分量的个数,对 18 组 MEG 数据进行分析,选取每组 MEG 数据的前 15 个主成分进行分析。表 1 为其中一位正常受试者 (Normal) MEG 数据经 PCA 降维后前 15 个主成分对应的贡献率。

表 1 贡献率

主成分	贡献率/%	主成分	贡献率/%
MI ₁	39.977 8	MI ₉	1.891 2
MI ₂	13.582 1	MI ₁₀	1.587 7
MI ₃	10.782 1	MI ₁₁	1.344 6
MI ₄	8.722 2	MI ₁₂	1.052 9
MI ₅	6.831 0	MI ₁₃	0.808 5
MI ₆	3.936 8	MI ₁₄	0.710 4
MI ₇	3.805 1	MI ₁₅	0.538 4
MI ₈	2.520 7	SUM	98.091 5

最后对降维后的 15 个主成分 MEG 信号用矩形窗进行分段^[21],每 1 000 个数据点分一段,下一段与上一段数据重叠 500 个点。这样每一个主成分 20 s 的数据就被分为 5 段,每一位受试者的 MEG 数据共分为 75 段数据样本,每个样本的长度为 1 000 个数据点。

2.2 实验过程与结果分析

在特征提取中选用 Db2 小波函数对每一段 MEG 数据进行 4 层小波包分解,并根据对数能量熵准则选取最优小波包基。图 1 为对 PCA 降维后的一段脑磁

信号小波包分解后的最优小波包基的选择结果。




图 1 最优小波包基选择结果示意图

从图中可以看出,通过最优小波基的选取可以在不影响信息量的同时减少二叉树的节点数。

图 2 是对选择出的最优小波包基的小波包系数进行 AM 调制后的包络图。最后提取每个包络的能量熵,对能量熵求取统计特性,包括最大值、最小值、均值和方差。




图 2 小波包系数进行 AM 调制的包络图

此外使用单因素分析方法对两类 MEG 数据提取的四维特征向量 (能量熵的最大值、最小值、均值、方差) 进行分析,表 2 是单因素分析的结果。

表 2 单因素分析结果

能量熵特征值	最大值	最小值	均值	方差
P 值	3.827 4E-09	0.028 7	4.561 5E-12	3.858 6E-13

从表中可以看出,按文中提出的方法从正常人 (Normal) 和精神分裂症病人 (Patient) 的两类脑磁信号中提取的特征值是有显著性差异的。为了进一步分析文中提取的正常人脑磁信号和精神分裂症病人脑磁信号的特征差异,分别分析了文中提取的正常人脑磁信号和精神分裂症病人脑磁信号的特征盒形图,如图 3 所示。从图中可以看出,两类样本是有明显差别的。

文中分别将能量熵的最大值、最小值、均值、方差组合成的 4 维特征向量作为 SVM 的输入。将预处理后的 675 个正常人脑磁数据和 675 个精神分裂症病人的脑磁数据随机等分为 9 个子集,进行 0 到 1 归一化操作后,从中分别选出 8 个子集作为训练样本,交叉验证求取 SVM 中的最优参数,剩余一组子集作为测试样本,以 9 次识别率的均值作为平均识别率。

图 4 给出了参数选择的结果图。

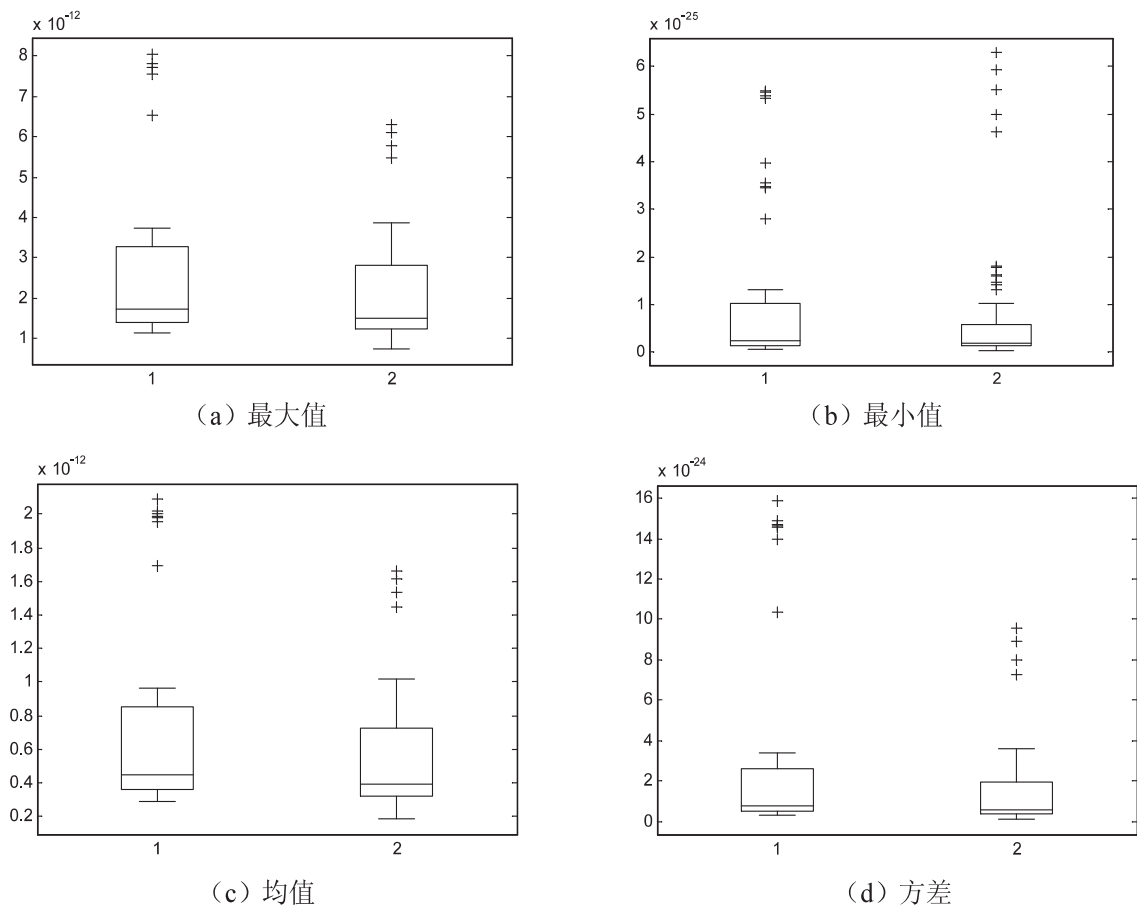


图3 正常人脑磁信号和精神分裂症病人脑磁信号的特征盒形图

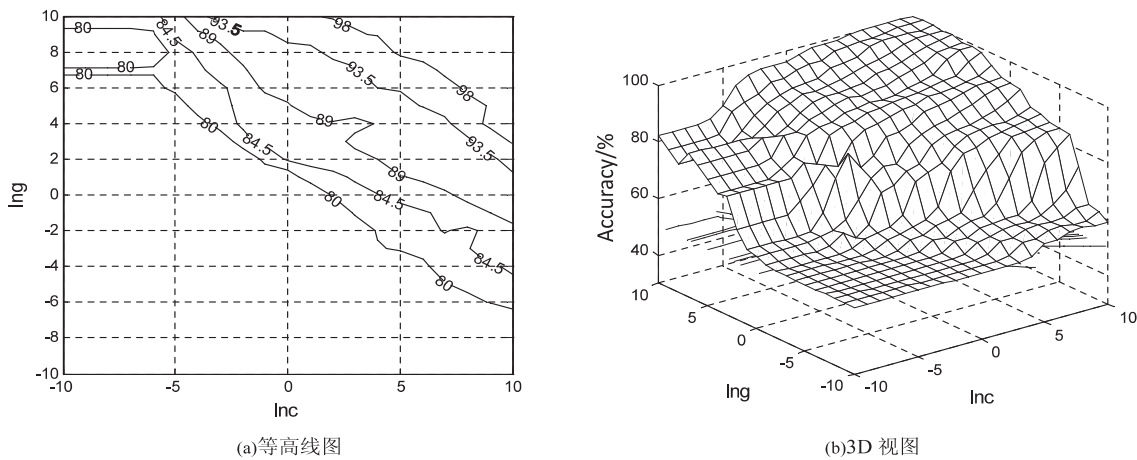


图4 SVM 参数选择结果图

从图4可以看出,当参数 c 取1 024, g 取32时,训练的正确率为100%,测试样本正确率为97.586 8%。

表3给出了基于文中的小波包基与能量熵的特征提取方法的分类结果与其他特征提取方法分类结果的比较。实验结果表明:文中提出的基于小波包基与能

表3 分类准确率对比

特征提取方法	分类准确率/%
WPD ^[9]	70
DWT+AM ^[10]	81.428 6
文中方法	97.586 8

量熵的MEG自动分类方法的准确率较高,高于表中列出的现有方法。

3 结束语

文中提出了一种新的脑磁特征提取与识别的方法。该方法从新的角度结合小波包分析,最优小波包基选取,以及对小波包系数的幅度调制,来提取正常人与精神病患者的脑磁特征。同时为了减少特征向量的维数,对幅度调制的包络求取能量熵来提取脑磁特征向量。文中考虑了个体的差异,针对每一个个体单独

求取特征向量,在分类阶段通过交叉验证寻求最佳分类器参数。实验结果表明,基于小波包基与能量熵的 MEG 自动分类方法有较高的分类准确度,分类准确率可达 97.586 8%。

参考文献:

- [1] 李 坤,褚蕾蕾,朱世东,等. 基于 mu 节律能量的运动意识分类研究[J]. 计算机技术与发展,2006,16(8):157-159.
- [2] 罗志增,李亚飞,孟 明,等. 脑电信号的混沌分析和小波包变换特征提取算法[J]. 仪器仪表学报,2011,32(1):33-39.
- [3] 文 念,黄丽亚,于 涵,等. 基于 ICA 和聚类的 EEG 脑源定位研究[J]. 计算机技术与发展,2015,25(5):228-232.
- [4] Zhukov L, Weinstein D, Johnson C. Independent component analysis for EEG source localization[J]. IEEE Engineering in Medicine and Biology Magazine,2000,19(3):87-96.
- [5] 侯凤贞,戴加飞,刘新峰,等. 基于网络连接度指标的脑梗死患者脑电信号相同步分析[J]. 物理学报,2014,63(4):59-64.
- [6] Huberle E, Lutzenberger W. Temporal properties of shape processing by event-related MEG adaptation[J]. NeuroImage, 2013,67:119-126.
- [7] Cravo A M, Rohenkohl G, Wyart V, et al. Temporal expectation enhances contrast sensitivity by phase entrainment of low-frequency oscillations in visual cortex[J]. The Journal of Neuroscience,2013,33(9):4002-4010.
- [8] Mirzaei A, Ayatollahi A, Gifani P, et al. EEG analysis based on wavelet-spectral entropy for epileptic seizures detection[C]//Proc of 3rd international conference on biomedical engineering and informatics. [s. l.]:IEEE,2010:878-882.
- [9] 王 登,苗夺谦,王睿智. 一种新的基于小波包分解的 EEG 特征抽取与识别方法研究[J]. 电子学报,2013,41(1):193-198.
- [10] 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.
- [11] Kremer J, Pedersen K S, Igel C. Active learning with support vector machines[J]. Wiley Interdisciplinary Reviews Data Mining & Knowledge Discovery,2014,4(4):313-326.
- [12] Hsu W Y, Lin C H, Hsu H J, et al. Wavelet-based envelope features with automatic EOG artifact removal; application to single-trial EEG data[J]. Expert Systems with Applications, 2012,39(3):2743-2749.
- [13] Coifman R R, Wickerhauser M V. Entropy-based algorithms for best basis selection[J]. IEEE Transactions on Information Theory,1992,38(2):713-718.
- [14] 张德丰. MATLAB 小波分析[M]. 北京:机械工业出版社,2009:158-163.
- [15] Clochon P, Fontbonne J M, Lebrun N, et al. A new method for quantifying EEG event-related desynchronization: amplitude envelope analysis[J]. Electroencephalography and Clinical Neurophysiology,1996,98(2):126-129.
- [16] 胡剑锋,穆振东,肖 丹. 基于能量熵的运动想象脑电信号分类[J]. 计算机工程与应用,2008,44(33):235-238.
- [17] 陈 悦,张少白. LM 算法在神经网络脑电信号分类中的研究[J]. 计算机技术与发展,2013,23(2):119-122.
- [18] Cortes C, Vapnik V. Support-vector networks[J]. Machine Learning,1995,20(3):273-297.
- [19] Zhang X J, Wang Y T, Wang Y J, et al. Ultra-slow frequency bands reflecting potential coherence between neocortical brain regions[J]. Neuroscience,2015,289:71-84.
- [20] Lin C T, Wang Y K, Chen S A. An EEG-based brain-computer interface for dual task driving detection[C]//Proc of neural information processing. Berlin:Springer,2011:701-708.
- [21] Nakayama K, Kaneda Y, Hirano A. A brain computer interface based on FFT and multilayer neural network-feature extraction and generalization[C]//Proc of ISPACS. Xiamen:IEEE, 2008:826-829.

(上接第 126 页)

- [7] 雍雅琴. 数字助听器中主要语音信号处理方法研究[D]. 北京:北京协和医学院,2013.
- [8] 王青云,赵 力,赵立业,等. 一种数字助听器多通道响度补偿方法[J]. 电子与信息学报,2009,31(4):832-835.
- [9] 张宝琳,张玲华. 数字助听器中多通道响度补偿方法的研究[J]. 信号处理,2013,29(5):656-661.
- [10] Rothweiler J H. Polyphase quadrature filters—a new subband coding technique[C]//Proc of IEEE ICASSP. [s. l.]:IEEE, 1983.
- [11] 张 晨,李双田. 设计 QMF 组的一种新算法及基于 GA 的优化[J]. 信号处理,2005,21(2):120-125.
- [12] 孟 君. 基于 DSP 的数字助听器多通道响度补偿方案[J]. 南京信息工程大学学报:自然科学版,2010,2(5):420-425.
- [13] 李 丽. 非均匀滤波器组的研究[D]. 西安:西安电子科技大学,2009.
- [14] Huang J, Gu G X. A direct approach to the design of QMF banks via frequency domain optimization[J]. IEEE Transaction on Signal Processing,1998,46(8):2131-2138.