

# 基于 EEMD 和 GA-SVM 的精神分裂症 MEG 识别

张学军<sup>1,2</sup>, 朱丽敏<sup>1</sup>, 黄丽亚<sup>1,2</sup>, 成谢锋<sup>1,2</sup>

(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:**为了研究脑磁图(MEG)信号在识别精神分裂症方面的应用,文中提出了一种基于总体经验模态分解(EEMD)和希尔伯特(Hilbert)变换的识别方法。在对正常人和精神分裂症患者的脑磁信号进行预处理的基础上,通过 EEMD 方法将信号分解为一系列的固有模态函数(IMFs),然后使用 Hilbert 变换求取固有模态函数的瞬时频率和振幅,由希尔伯特-黄幅度谱(HHS)和边际谱(MS)可以发现两类信号的差异;接着选取与原信号相关性较高的前 9 个 IMF 的瞬时频率和振幅归一化后计算 Hilbert 加权频率;最后,利用经遗传算法(GA)优化的支持向量机(SVM)分类器进行分类,并与  $k$  近邻(KNN)分类器的结果进行对比,得到的分类精确度分别为 95% 和 78.33%,验证了所提识别方法的有效性。

**关键词:**脑磁信号;总体经验模态分解;希尔伯特变换;遗传算法;支持向量机; $k$  近邻

中图分类号:R318

文献标识码:A

文章编号:1673-629X(2016)08-0166-05

doi:10.3969/j.issn.1673-629X.2016.08.035

## Recognition of Schizophrenic MEG Based on EEMD and GA-SVM

ZHANG Xue-jun<sup>1,2</sup>, ZHU Li-min<sup>1</sup>, HUANG Li-ya<sup>1,2</sup>, CHENG Xie-feng<sup>1,2</sup>

(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:** In order to study the significance of magnetoencephalography (MEG) in recognition of schizophrenia, a method based on Ensemble Empirical Mode Decomposition (EEMD) and Hilbert Transform (HT) is described in this paper. Firstly, on the basis of preprocessing of magnetoencephalography for the normal and schizophrenia, EEMD is used to decompose signals into a series of intrinsic mode functions, then instantaneous frequency and amplitude of IMFs can be obtained by HT, and the differences can be found between two types of signals from the Hilbert spectrum and the marginal spectrum. Secondly, the instantaneous frequency and amplitude of the first 9 IMFs which have higher correlation with original signals is selected to calculate the Hilbert weighted frequency after they are normalized. Finally, Support Vector Machine (SVM) optimized by Genetic Algorithm (GA) is adopted for classification, and the results are compared with the K-Nearest Neighbor (KNN) classifier. The accuracy of classification obtained by the two methods are 95% and 78.33% respectively, which verifies the validity of this method roughly.

**Key words:** magnetoencephalography; EEMD; HT; GA; SVM; KNN

## 1 概述

脑磁图(Magnetoencephalography, MEG)是在脑电图(Electroencephalograph, EEG)之后发展起来的又一项脑功能检测技术。MEG 对脑部损伤的定位诊断比 EEG 更为准确,它通过超导量子干涉仪 SQUID 对人脑进行非侵入性的测量,得到由脑内神经活动产生的头外微弱磁场,能够反映出毫秒时间范围内的神经活

动变化<sup>[1]</sup>。

精神分裂症(Schizophrenia)是一种严重的精神病症,多在青壮年时期缓慢或亚急性起病,其特征包括幻觉、妄想、偏执狂、认知损害、社交退缩、自我忽视以及失去动力及主动性等。将 MEG 用于精神分裂症患者的研究,不但可以发现患者磁反应波潜伏期及波幅等异常,更可以探测脑磁源信号的位置变化,且不受颅骨

收稿日期:2015-10-16

修回日期:2016-01-21

网络出版时间:2016-06-21

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;朱丽敏(1991-),女,硕士研究生,研究方向为智能信息处理。

网络出版地址: <http://www.cnki.net/kcms/detail/61.1450.TP.20160621.1701.016.html>

及软组织影响,有助于更好地了解该疾病。

MEG 信号是一种时变的非平稳信号,对于这类信号的分析,希尔伯特-黄变换(Hilbert-Huang Transform, HHT)<sup>[2-4]</sup>是一种更具优越性的有效时频分析方法。该方法通过经验模态分解(Empirical Mode Decomposition, EMD)<sup>[5]</sup>将非平稳信号自适应分解成一系列具有物理意义的窄带信号,即固有模态函数(Intrinsic Mode Function, IMF),并对各层 IMF 进行 Hilbert 变换,从而提取瞬时幅度、瞬时相位和频率等信息。同时,依据信号幅度在整个频段上随时间和瞬时频率的变化可以定义希尔伯特-黄幅度(HHS),在时间进行积分,则可以得到边际谱(MS)<sup>[6]</sup>。因此,HHT 在时域、频域同时具有很高的分辨率。为了解决 EMD 存在的模态混叠问题,之后又出现了它的改进算法:总体经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)<sup>[7-8]</sup>。EEMD 的基本思路是将白噪声加入到所需分解的信号中补充一些缺失的尺度,进而达到更好的分解结果。该算法有两个重要参数:所加白噪声幅值(系数  $k$ , 通常为 0.1 ~ 0.4)和分解次数  $M$ 。关于如何选取白噪声幅值并没有公式可循,只有通过多次尝试从而选出最合适的值<sup>[9]</sup>。文中的 EEMD 过程  $k$  值取 0.4,  $M$  取 100。

文中提出一种基于改进 Hilbert-Huang 变换和 GA-SVM 对 MEG 信号进行识别的方法。首先,利用 EEMD 将正常人和患者各 9 名受试者的 MEG 信号分解成一系列固有模态函数(IMFs)。然后,计算各 IMF 分量和原信号的相关系数,选出与原信号相关性较高的 9 个 IMFs 进行 Hilbert 变换,求得其 Hilbert 瞬时频率和振幅,对频率和振幅归一化后计算 Hilbert 加权频率。最后,运用遗传算法<sup>[10]</sup>(Genetic Algorithms, GA)对支持向量机(Support Vector Machine, SVM)模型参数进行优选<sup>[11]</sup>,将预测值的均方误差作为遗传寻优的适应度函数(适应度越小,代表预测值越精确),从而寻找到最优的 SVM 模型用于分类。并将分类结果与  $k$  近邻(K-Nearest Neighbor, KNN)分类器的结果进行比较<sup>[12]</sup>。

## 2 数据处理及特征提取

文中使用的脑磁数据来源于美国 NIMH(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<sup>[13]</sup>。实验选取的数据包含两类:正常人和精神分裂症患者。各取 9 名受试者,MEG 信号采样频率为 600 Hz,持续时间为 240 s。将 275 个通道分成 10 个区域,并在每个区域选择 1 个典型的通道数据进行分析,这 10 个通道为:MLF14,MLC16,MLP57,MLT44,MRT44,MLO33,

MRO33,MRF14,MRC16,MRP57。

### 2.1 数据预处理

在特征提取之前,先对两类受试者的脑磁数据进行预处理,并将采样频率由 600 Hz 降至 150 Hz,以降低数据存储量,提高分类效率。

文中用于分析的脑磁数据是除去噪声和伪迹后的,而实际采集时 MEG 信号会被许多噪声和伪迹成分(眼电、心电伪迹,工频干扰和电源线噪声等)所污染。常见的用于去除噪声和伪迹的方法有:独立分量分析、主成分分析、自适应滤波和小波变换等。另外,在此基础上又出现了一些改进方法,如结合主成分分析和独立成分分析的去噪/伪迹方法、利用非线性参数并基于盲源分离的伪迹自动去除方法等。与常规方法相比,这些方法很大程度上改善了去噪/伪迹的性能。

### 2.2 特征选择

特征选择步骤如下:

步骤 1:对每名受试者 10 个典型通道的 MEG 数据进行 EEMD 分解,得到每个信号的固有模态函数。文中 EEMD 分解仅取决于信号长度  $T$ ,IMFs 的数量可以根据式(1)得到:

$$n = \log_2(T) \quad (1)$$

因此,文中的 EEMD 可将信号分解成 15 个 IMFs,其中第 15 个为残留。

步骤 2:相关性分析。分析各 IMF 分量和原信号的相关性,选出相关性较高的 IMFs,并对其进行 Hilbert 变换,从而构造解析信号:

$$z_s(t) = c_s(t) + jy_s(t) = a_s(t)e^{j\theta_s(t)} \quad (2)$$

步骤 3:从式(2)的解析信号分别提取出两类信号的瞬时幅度和瞬时频率。

步骤 4:根据式(3)对瞬时幅度和频率进行归一化:

$$y = (x - \text{MinValue}) / (\text{MaxValue} - \text{MinValue}) \quad (3)$$

步骤 5:利用式(4)求得对应的 Hilbert 加权频率<sup>[14]</sup>:

$$\bar{f} = \frac{\sum_{i=1}^n a(i)f^2(i)}{\sum_{i=1}^n a(i)f(i)} \quad (4)$$

步骤 6:利用  $t$  检验进行比较,选出两类信号中具有明显性差异的特征。

### 2.3 分类

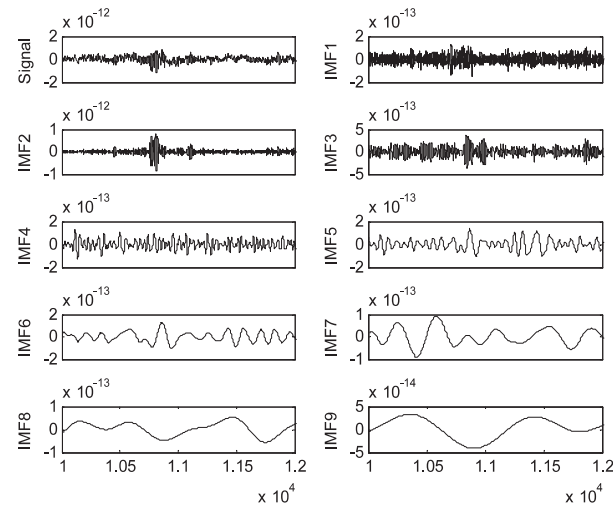
文中运用经 GA 算法优化后的 SVM 分类器和 KNN 分类器对提取特征后的 MEG 数据进行分类。对于正常人和精神分裂症患者两类信号,各有 90 个样本,选择其中的前 60 个作为训练集,剩余的 30 个作为测试集。因此,总的训练集包含 120 个样本,测试集则

包含 60 个样本。


3 实验结果与分析

首先,在正常人和精神分裂症患者中各选 1 名受试者,对 MLP57 通道的数据进行 EEMD 分解。图 1

(a)显示的是正常人 EEMD 分解后的 IMFs(此处只显示前 9 个)分量曲线;图 1(b)显示的是精神分裂症患者 EEMD 分解后的 IMFs 分量曲线。由图 1 可以看出,在经过 EEMD 分解之后,各个 IMFs 分量包含了从高到低不同频率段的成分。



(a)正常人




(b)精神分裂症患者


图 1 受试者 MEG 信号经 EEMD 后的 IMFs 分量曲线

为了将正常人和精神分裂症患者进行区分,分别对两名受试者的 MEG 信号进行 HHT,得到其时频图

(HHS)和边际谱(MS)(取 0 ~ 20 Hz 频率段),如图 2 和图 3 所示。




(a) 正常人




(b) 精神分裂症患者

图 2 正常人和精神分裂症患者 MEG 信号时频图



(a) 正常人



(b) 精神分裂症患者

图 3 正常人和精神分裂症患者 MEG 信号边际谱

从图 2 和图 3 中可以看出,正常人和精神分裂症

患者在频率较低部分的差异相对于频率较高部分更为

明显。为了更加精确地对正常人和患者进行区分,对每类受试者各 90 个通道的数据分别运用 EEMD,计算得到的各 IMFs 分量和原信号的相关系数,以  $p < 0.05$  为标准,经过整体计算,最终选择各信号的前 9 个 IMFs 分量进行进一步分析。

接着,对选出的各 IMFs 分量以其 Hilbert 加权频率作为特征,并利用  $t$  检验( $t < 0.01$ )进行比较,选出

两类信号中差异显著的特征。最后选出了 8 个 IMFs 分量(第 1,3,4,5,6,7,8,9 个 IMFs)的 Hilbert 加权频率作为最终的特征向量(正常人和患者特征向量的维数都为  $90 \times 8$ ),用于进一步的分类。从图 4 中也可以看出,两类信号第 1,3,4,5,6,7,8,9 个 IMFs 分量的加权频率差异较大。

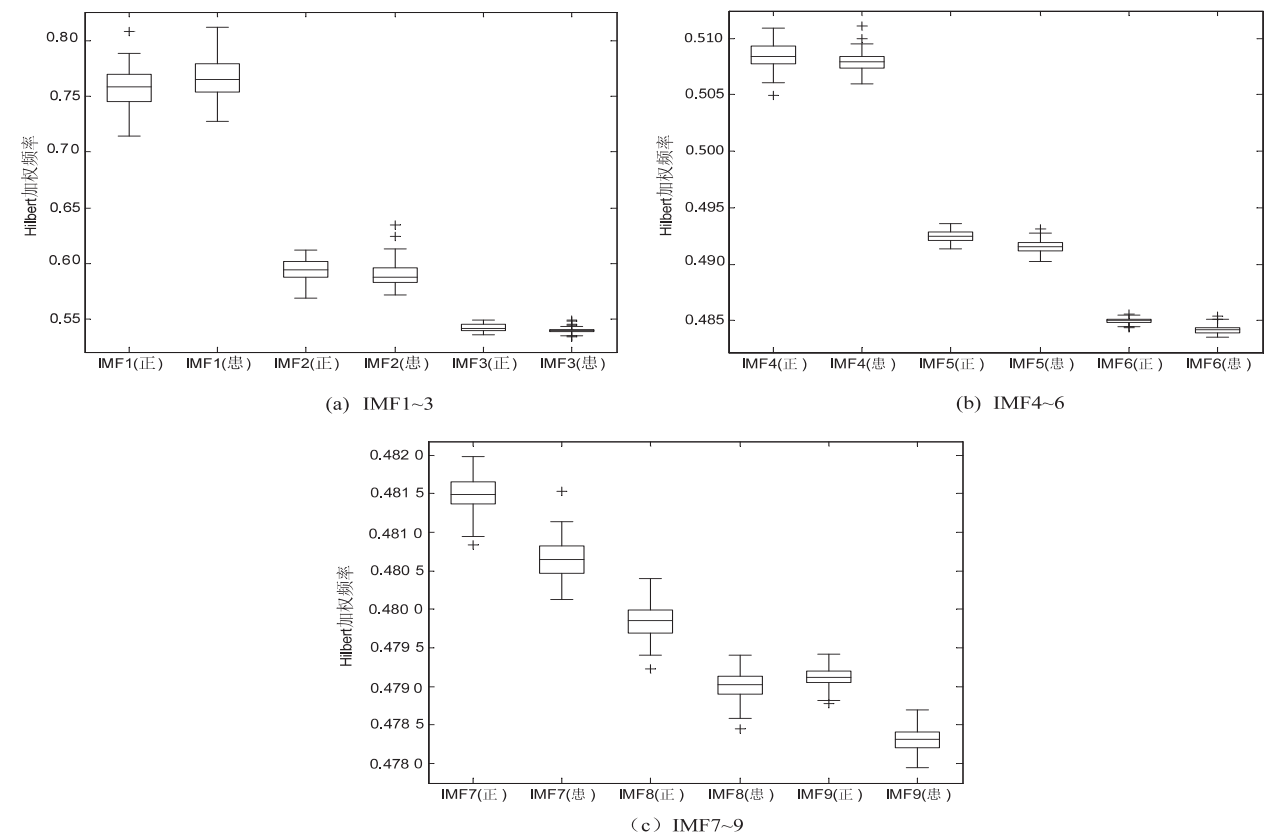


图4 正常人和精神分裂症患者 IMFs 箱线图

在得到用于分类的两类信号的特征向量之后,按上文所述分别设置其训练集和测试集,运用两种分类器对其进行分类。图 5(a)和(b)分别是利用两种分类

器得到的分类结果的分析情况,图中 1 表示正常人,-1 表示精神分裂症患者。




图5 两种分类器识别正常人和精神分裂症患者的结果

利用经遗传算法优化的 SVM 分类器得到的最佳 SVM 参数  $c$  和  $g$  分别为 96.906 9 和 99.584 3 (见图

6)。分类精确度(分类精确度=正确分类的样本数/总样本数)为 95%,利用  $k$  近邻分类器( $k=5$ )的分类精

确度为 78.33%。相比之下,利用 GA-SVM 分类器得到的结果更具优势。从最后的分类结果发现,文中方法对于区分正常人和精神分裂症患者来说是有效的。




图 6 GA 算法优化 SVM 模型参数结果

## 4 结束语

文中利用 EEMD 和 Hilbert 变换对 MEG 数据进行处理,首先利用 EEMD 将 MEG 数据分解为一系列的 IMF 分量,并对与原信号相关性较高的 IMF 分量运用 Hilbert 变换计算瞬时频率和瞬时振幅,进而求得 Hilbert 加权频率作为特征,然后利用  $t$  检验得到最终的特征向量,最后利用 GA 优化的 SVM 和  $k$  近邻分类器进行分类,得到分类结果。通过对正常人和精神分裂症患者两类数据进行分析,结果初步验证了文中所述方法在区分正常人和精神分裂症患者方面的有效性,有助于更好地利用 MEG 对该疾病进行研究。

### 参考文献:

[1] 胡洁,胡净,黄定君.脑磁图研究进展[J].生物医学工程与临床,2003,7(3):181-184.  
[2] 李明爱,崔燕,杨金福,等.基于 HHT 和 CSSD 的多域融合自适应脑电特征提取方法[J].电子学报,2013,41(12):2479-2486.

[3] Penga Z K, Tse P W, Chu F L. A comparison study of improved Hilbert-Huang transform and wavelet transform: application to fault diagnosis for rolling bearing[J]. Mechanical Systems and Signal Processing, 2005, 19: 974-988.  
[4] 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.  
[5] 王慧,刘正士,汪家慰,等.测试高分辨率 ADC 有效位数的 HHT 方法[J].电子学报,2009,37(9):2072-2076.  
[6] 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].生物医学工程学杂志,2013,30(2):249-253.  
[7] Amirat Y, Benbouzid M, Wang T, et al. Performance analysis of an EEMD-based Hilbert Huang transform as a bearing failure detector in wind turbines[C]//Proc of international conference on green energy. [s. l.]: IEEE, 2014: 193-198.  
[8] Mariyappa N, Sengottuvel S, Parasakthi C, et al. Baseline drift removal and denoising of MCG data using EEMD: role of noise amplitude and the thresholding effect[J]. Medical Engineering & Physics, 2014, 36(10): 1266-1276.  
[9] Lei Y G, He Z J, Zi Y. Application of the EEMD method to rotor fault diagnosis of rotating machinery[J]. Mechanical System and Signal Processing, 2009, 23(4): 1327-1338.  
[10] 袁玲,杨帮华,马世伟.基于 HHT 和 SVM 的运动想象脑电识别[J].仪器仪表学报,2010,31(3):649-654.  
[11] Hiesh M H, Lam Y Y A, Shen C P, et al. Classification of schizophrenia using Genetic Algorithm-Support Vector Machine (GA-SVM) [C]//Proc of 35th annual international conference of IEEE engineering in medicine and biology society. [s. l.]: IEEE, 2013: 6047-6050.  
[12] 叶柠,孙宇舸,王旭.基于共空间模式和 K 近邻分类器的脑-机接口信号分类方法[J].东北大学学报:自然科学版,2009,30(8):1107-1110.  
[13] Zhang Xuejun, Wang Yute, Wang Yijun, et al. Ultra-slow frequency bands reflecting potential coherence between neocortical brain regions[J]. Neuroscience, 2015, 289: 71-84.  
[14] van Zaen J. Adaptive tracking of EEG oscillations[J]. Journal of Neuroscience Methods, 2010, 186(1): 97-106.