

基于经验模态分解和 SVM 的脑电信号分类方法

彭仁旺

(广东科学技术职业学院, 广东 珠海 519000)

摘要: 脑电信号的非线性、非平稳性造成对运动想象脑电信号的分类识别存在特征提取困难、可区分性低以及分类识别性能差等问题; 文章提出一种基于经验模态分解 (empirical mode decomposition, EMD) 和支撑向量机 (support vector machine, SVM) 的运动想象脑电信号分类方法, 充分利用 EMD 算法在处理非线性、非平稳信号的自适应性以及 SVM 在小样本条件的高识别性能和强泛化能力; 首先利用 EMD 算法将 C3、C4 导联信号分解为一系列本征模函数 (intrinsic mode function, IMF), 然后从 IMF 的信息和能量等维度提取特征将脑电信号转换至区分性更强的特征域, 最后利用 SVM 进行分类识别; 采用国际 BCI 竞赛 2003 中的 Graz 数据进行验证, 所提方法可以得到 94.6% 的正确识别率, 为在线脑-机接口系统的研究提供了新的思路。

关键词: 脑电信号分类; 经验模态分解; 支撑向量机; 特征提取

Classification Method of EEG Based on Empirical Mode Decomposition and SVM

Peng Renwang

(Guangdong Vocational College of Science and Technology, Zhuhai 519000, China)

Abstract: The non-linearity and non-stationary characteristics of EEG signal make it difficult to extract features and classify them into different categorizes. This paper proposes a classification method of EEG signals based on empirical mode decomposition (EMD) and support vector machine (SVM), which makes full use of the adaptive ability of EMD algorithm in dealing with nonlinear and non-stationary signals, as well as the high identification performance and strong generalization ability of SVM in small sample conditions. Firstly, C3 and C4 lead signals are decomposed into a series of intrinsic mode function (IMF) by EMD algorithm, and then features are extracted from IMF's information and energy dimensions to transform EEG signals into more discriminable feature domain, and finally SVM is utilized to classification EEG signals into different categorizes. Using Graz data from international BCI competition 2003, the proposed method can achieve a correct recognition rate of 94.6%, which providing a new idea for the study of online brain-computer interface system.

Keywords: classification of EEG signals; empirical mode decomposition; support vector machine; feature extraction

0 引言

近年来, 在计算机科学、生物医学以及人工智能等技术发展的推动下, 作为交叉学科的脑-机接口 (brain computer interface, BCI) 技术也取得了长足的进步。BCI 技术不依赖于脑外周肌肉系统等传统的大脑输出通路, 而是直接通过计算机或其他外围设备对特定任务下的脑电信号 (electro encephalogram gram, EEG) 进行分析, 将不同思维活动产生的 EEG 与不同指令 (如鼠标的移动等) 联系起来, 达到向外界传达大脑中的信息或控制命令的目的。BCI 技术理论上具备代替语言和肢体活动的潜能, 使人的意念控制变为现实, 在自动驾驶、通信娱乐以及帮助残障人士重新恢复信息通信功能等方面具有广阔的应用前景^[1-2]。

BCI 研究中的关键是对脑电信号的特征提取和分类识别: 特征提取是从脑电信号中提取反映不同思维活动的差异信息, 并通过剔除冗余信息达到降低运算量的目的。分

类识别是通过构建合适的分类器对特征提取阶段获得的特征向量进行有效区分, 需要在保证分类性能和计算效率的前提下具备较强的泛化能力。

目前对脑电信号特征提取的研究主要分为 3 个方向: 一是从信号的时域、频域以及时频域等变换域提取特征, 典型的有快速傅里叶变换法 (fast fourier transformation, FFT), 短时傅里叶变换法 (short time fourier transformation, STFT), 功率谱分析法以及小波变换法等^[3-8], 其中 FFT 方法, 功率谱分析方法将时域信号转换到频域, 虽然能够得到信号的频域信息, 但是损失了时间信息, 在分析非线性、非平稳信号时存在明显的局限性; STFT 方法虽然能够分析信号的局部特征, 但是根据信号测不准原理, STFT 方法时间分辨率和频率分辨率存在不可以调和的矛盾, 即时间分辨率越高则频率分辨率越低, 反之亦然; 小波变换方法具备的多分辨率特性, 在分析非线性、非平稳信号时具备明显优势, 通过将信号投影到一系列“基函数”上实现信号分解, 然而“基函数”的选择对小波方法的分类性能影响较大。二是从空间域提取特征, 主要分为共空间模式法 (CSP) 和独立分量分析法 (ICA) 等^[9-10], CSP

收稿日期: 2019-06-06; 修回日期: 2019-07-05。

作者简介: 彭仁旺 (1981-), 男, 广东陆河人, 中级, 硕士学位, 主要从事计算机方向的研究。

方法需要对脑电信号进行多通道分析, 虽然能够获得较好的结果但是以增加系统复杂度和运算量为代价的, 限制了在实际中的应用, ICA 方法能够有效的增强 EEG 信号中的重要节律分量, 但是由于 EEG 信号的非线性、非平稳特性, ICA 提取的主分量很难有合理的物理解释。三是参数模型分析方法, 典型方法包括参数模型功率谱估计, 自回归滑动平均模型 (ARMA) 等, 该类方法运算量小, 适合在线分析, 但受噪声影响较大, 常用于分析平稳随机信号。

得到特征向量后, 需要设计合适的分类算法才能得到的期望的分类性能。当前应用比较广泛的分类方法主要有: 线性分类器, 神经网络分类器、支撑向量机 (support vector machine, SVM) 和贝叶斯分类器等^[11], 其中 SVM 作为一种统计分类方法, 在面对小样本、非线性以及高维模式分类问题时表现出了出众的性能, 受到广泛关注与应用。

在上述研究工作的基础上, 针对 EEG 信号的非平稳、非线性特征, 本文提出一种基于 EMD 和 SVM 的方法对 EEG 信号进行特征提取和分类识别, 不同于传统的 FFT 和小波变换将信号投影到一组预先设定的“基函数”上实现对信号的分解, EMD 算法根据信号的局部特征, 从信号中自适应的提取一系列本征模函数 (intrinsic mode function, IMF), 然后从 IMF 中提取特征向量, 最后采用 SVM 分类器对所提特征向量进行分类识别, 基于实测数据的实验结果表明, 所提方法可以获得理想的分类结果。

1 实验数据介绍

本文采用奥地利 Graz 科技大学脑-机接口实验中心提供的运动想象脑电数据, 该数据为 2003 年国际 BCI 竞赛中的标准数据。实验过程中要求受试者按提示方向进行左右手运动想象。实验过程中的时序如图 1 所示, 每次试验时间持续 9 s。其中, 0~2 s 为准备时间, 受试者处于放松静止状态, 第 2 s 时, 屏幕上出现一个交叉的“+”符号提示受试者实验即将开始。从第 3 s 开始, “+”符号被向右或向左的箭头替代, 同时要求受试者按照箭头提示的方向想象左手或右手的运动。实验采用 AgCl 电极, 数据从国际标准的 10~20 导联系统的 C3, CZ, C4 三个通道获取, 实验总共开展 280 次, 包含训练数据 140 组和测试数据 140 组, 训练数据和测试数据中一半 (70 次) 为想象左手运动, 一半 (70 次) 为想象右手运动。根据运动想象脑电生理学原理, 人体大脑的 C3, C4 通道包含了想象对侧运动时最为丰富的信息, 而 CZ 作为参考通道, 与运动想象没有太大的相关性, 因此实际分析中只采用 C3 和 C4 两个通道的数据。实验数据的采样频率为 128 Hz, 每次实验时长 9 s 包含 1152 个采样数据, 由于每次试验是从第 3 s 开始, 为了降低运算时间, 本文对每次实验取 3~9 s 共 768 个采样数据。

2 经验模态分解及数据分析

2.1 经验模态分解

EMD 最早由美籍华人 Huang, 于 1998 年提出, 是一种用来对非线性、非平稳信号进行自适应分解的算法^[12]。不

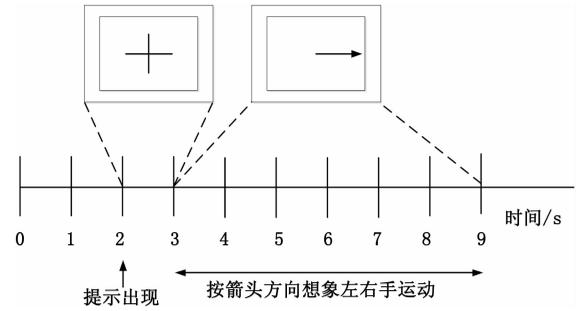


图 1 实验过程中的时序

同于 FFT 和小波变换, EMD 不需要预先设定一组基函数来度量信号, 而是根据信号的局部特征, 自适应的将信号分解为一系列被称为本征模函数 (intrinsic mode function, IMF) 的信号分量, 这些 IMF 是直接信号中提取出来的, 能够完整的反映原始信号的内在特征。IMF 需要满足如下两个条件:

- 1) 从待分析信号中提取的极大值点和极小值点的样本个数和与过零点的样本个数相差不超过 1 个;
- 2) 在待分析信号的任意位置处, 由局部极大值构成的上包络线和局部极小值构成的下包络线相对于时间轴对称, 即均值为 0。

对于任意给定的时间信号 $x(t)$, 计算第一个 IMF 的“筛选”算法步骤如表 1 所示。

表 1 计算 IMF 的“筛选”算法步骤

计算 IMF 的“筛选”算法步骤
1. 初始化: 将输入的时域信号 $x(t)$ 记为 $r(t) = x(t)$;
2. 计算 $r(t)$ 中的局部极大值序列, 用三次样条函数对局部极大值序列插值构造 $r(t)$ 的上包络 $r_{\max}(t)$;
3. 计算 $r(t)$ 中的局部极小值序列, 用三次样条函数对局部极小值序列插值构造 $r(t)$ 的下包络 $r_{\min}(t)$;
4. 计算每个时刻上包络和下包络的平均值, 得到瞬时平均值 $m(t)$, $m(t) = \frac{r_{\max}(t) + r_{\min}(t)}{2}$;
5. 从时域号中减去瞬时平均值, 得到新的时域信号 $r(t) = r(t) - m(t)$;
6. 根据 IMF 的两个条件对 $r(t)$ 进行判断, 若 $r(t)$ 满足 IMF 的形成条件, 则将其记为 imf_1 ; 否则根据步骤 2 到步骤 5 对 $r(t)$ 进行重复迭代运算, 直到 $r(t)$ 满足 IMF 的两个形成条件, 记为 imf_1 ;

在得到第一个本征模函数后, 我们计算得到剩余项 $q(t) = x(t) - imf_1$, 并将其作为新的输入信号, 采用上述“筛选”步骤得到下一个 IMF。经过多次“筛选”, 我们可以得到原信号的 EMD 分解结果为:

$$x(t) = \sum_{i=1}^L imf_i + r_L \quad (1)$$

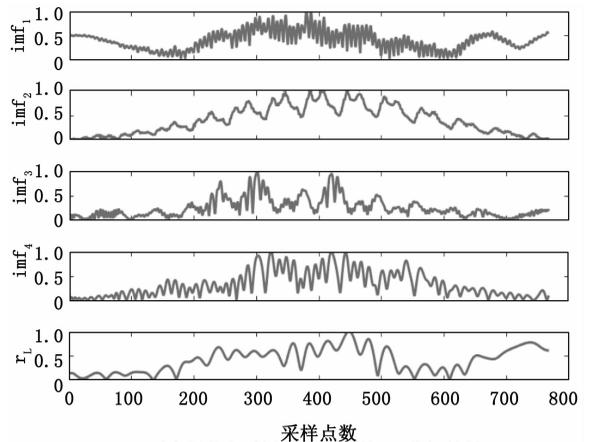
其中: imf_i 为第 i 个 IMF, r_L 为经过 L 次分解后的剩余项。

文献 [13] 分析指出, 在对信号进行分解时, EMD 所

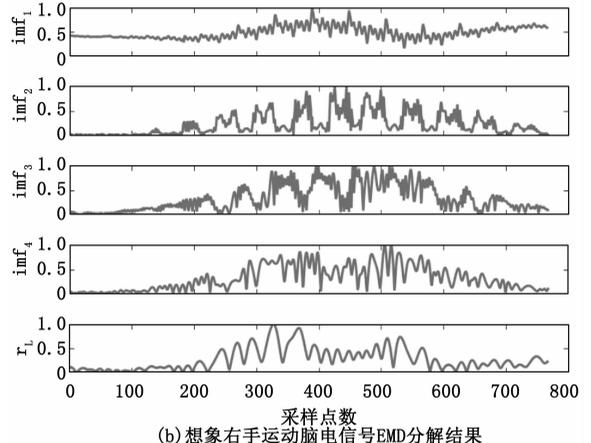
起的作用类似于利用一组相互重叠的滤波器组对信号进行滤波，EMD 分解的第一个 IMF 可以认为是通带为上半信号带宽的高通滤波器，之后的 IMF 可以认为是通带以二分之一缩减的带通滤波器组，即每个滤波器能够实现对剩余信号上半频带的滤除，由于 EMD 的通带范围是与信号带宽相关的，因而可以认为 EMD 对信号的分解是自适应的，即不需要提前设定基函数就能够自适应的从信号中提取不同频率对应的 IMF 分量。

2.2 数据分析

利用 EMD 算法对 C3 通道和 C4 通道的 EEG 信号进行分解，得到的结果如图 2 和图 3 所示，其中图 2 (a) 和图 3 (a) 为想象左手运动得到的 EEG 信号分解结果，图 2 (b) 和图 3 (b) 为想象右手运动得到的 EEG 信号分解结果，经过 EMD 分解后原始 EEG 信号被分解为 4 个 IMF 和一个余项。从图 2 和图 3 可以看出，在对想象左手运动和想象右手运动 EEG 信号进行 EMD 分解后，IMF2 和 IMF3 两个分量存在明显的区别，表 2 给出了分解得到的每个 IMF 信号分量的频段范围。根据奥地利 Graz 研究中心研究，当大脑进行运动想象时，位于头皮层左右两侧 EEG 信号的 α 节律 (8~12 Hz) 和 β 节律 (18~26 Hz) 的能量会发生相应的变化，这种电生理现象称为时间相关去同步 (event-related desynchronization, ERD) 或时间相关同步 (event-related



(a) 想象左手运动脑电信号 EMD 分解结果



(b) 想象右手运动脑电信号 EMD 分解结果

图 3 EEG 信号 EMD 分解结果 (C4 通道)

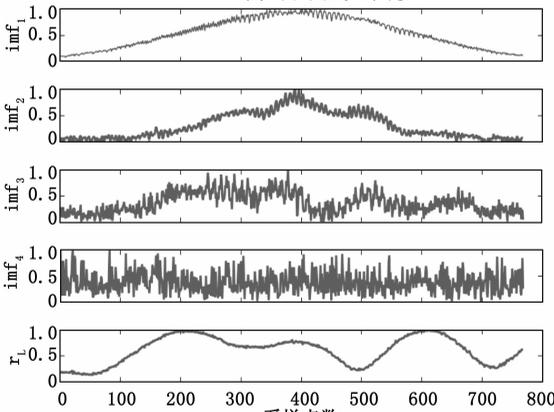
synchronization, ERS), ERD 和 ERS 是最能反映认知特性和最具生理意义的特征指标之一。而从表 2 可以看出，EEG 信号的 α 节律 (8~12 Hz) 和 β 节律 (18~26 Hz) 的频率范围刚好处于 IMF2 和 IMF3，也就是说，经过 EMD 分解后最能反映运动想象节律特征的信息被自适应的分解到 IMF2 和 IMF3 两个本征模函数中。因此，本文选择 IMF2 和 IMF3 进行进一步分析并提取特征对两种运动想象脑电信号进行分类。

表 2 EMD 分解后各分量频段范围

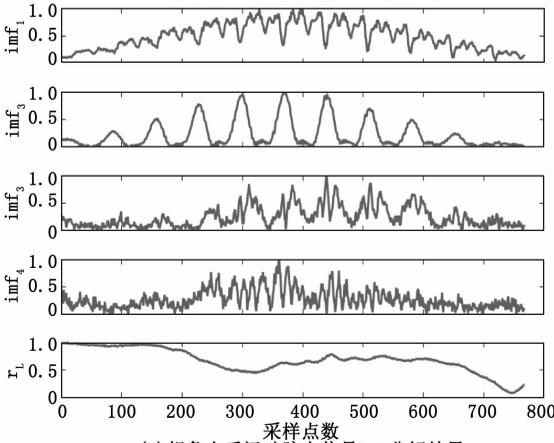
分解的信号	频率范围(Hz)
IMF1	32 ~ 64
IMF2	16 ~ 32
IMF3	8 ~ 16
IMF4	4 ~ 8
余项	0 ~ 4

2.3 特征提取

在得到 IMF2 和 IMF3 后，一种最直接的方法是利用 IMF2 和 IMF3 作为特征向量进行分类，但是由于 IMF2 和 IMF3 的维度较高，直接使用原始信号进行分类存在计算量大的问题。因此，本文通过提取以下特征对 IMF2 和 IMF3 的分布特性进行描述，降低特征向量维度的同时不影响分



(a) 想象左手运动脑电信号 EMD 分解结果



(b) 想象右手运动脑电信号 EMD 分解结果

图 2 EEG 信号 EMD 分解结果 (C3 通道)

类性能。

特征 1: IMF2 的熵: $F1 = entropy(imf_2) = - \sum_{f=1}^T p_f \log(p_f)$

其中, $p_f = \frac{imf_2(f)}{\sum_{f=1}^T imf_2(f)}$, $imf_2 = \{imf_2(f)\}_{f=1}^T$ 。熵

特征是从信号的信息分布的角度对信号进行度量, 信号信息分布越集中, 对应的熵越小, 也就是说, 信号越接近冲击函数, 对应的熵越小。

特征 2: IMF3 的熵: $F2 = entropy(imf_3) = - \sum_{f=1}^T p_f \log(p_f)$

其中: $p_f = \frac{imf_3(f)}{\sum_{f=1}^T imf_3(f)}$, $imf_3 = \{imf_3(f)\}_{f=1}^T$ 。

特征 3: IMF2 和 IMF3 的能量和占有 IMF 能量的百分比: $F3 = \frac{energy(imf_2) + energy(imf_3)}{\sum_{k=1}^M energy(imf_k)}$

其中: $energy(imf_k) = \sum_{f=1}^T imf_k^2(f)$, $k = 1, \dots, M$, M 为 EMD 分解的 IMF 个数。经过 EMD 分解后, 所有 IMF 的总能量能准确的反映运动想象 EEG 在整个时频空间能量的分布, 而 IMF2 和 IMF3 的能量和则充分体现了运动想象 EEG 在最重要节律上的局部能量分布, 因此特征 3 体现了局部和总体的相对关系。

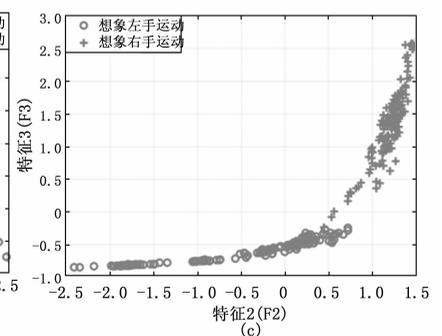
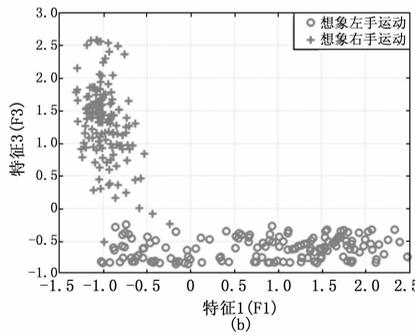
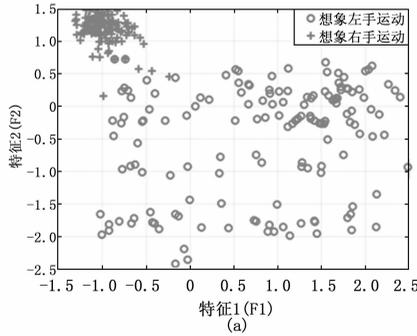


图 4 特征值分布图 (C3 通道)

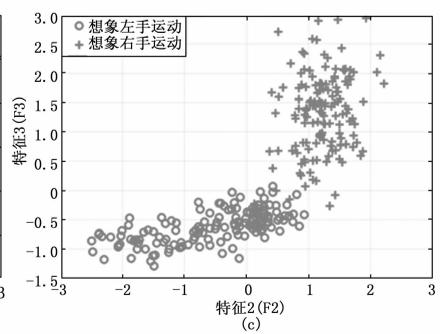
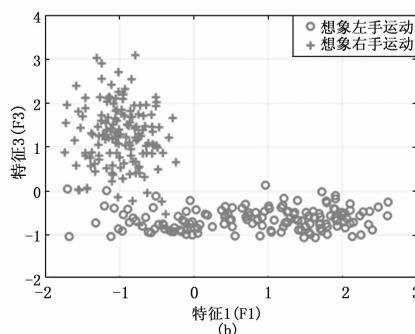
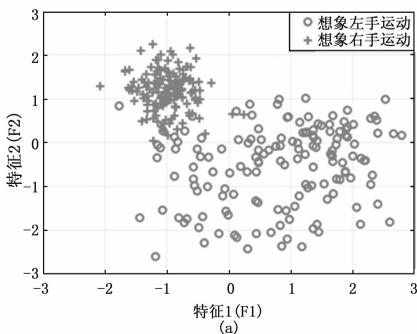


图 5 特征值分布图 (C4 通道)

图 4 和图 5 分别给出了对前述脑电信号数据提取上述三维特征得到的二维归一化特征值图, 其中圆圈表示想象左手运动 EEG 信号特征值, 加号表示想象右手运动 EEG 信号的特征值, 从图 4 和图 5 可以看出, 在特征域, 想象两种运动产生的 EEG 信号具有较好的可分性。

联合 C3 和 C4 两个通道可以得到如下包含六维特征的特征向量进行分类:

$$Feature = [F_{C3}1, F_{C3}2, F_{C3}3, F_{C4}1, F_{C4}2, F_{C4}3] \quad (2)$$

3 基于 EMD 和 SVM 的分类算法

3.1 SVM

SVM 是由 Vapnik 和 Cortes 于 1995 年在统计学习理论中的 VC 维和结构风险最小化原理的基础上建立起来的一种基于数据的模式分类方法, 在解决小样本, 非线性及高维模式分类问题中表现出许多特有的优势。

SVM 的核心思想是将输入低维空间中的线性不可分问题通过一种非线性变换转换为其他高维空间中的线性可分问题, 然后在该高维空间中寻找最优分类面, 其中低维空间到高维空间的非线性变换是通过核函数 $R(u_k, u_i)$ 实现的。引入核函数后, 非线性分类问题的分类函数转化为:

$$D(u) = \text{sgn} \left\{ \sum_{k=1}^K \tilde{a}_k R(u_k, u) + \tilde{\gamma} \right\} \quad (3)$$

其中: $\text{sgn}\{\}$ 为符号函数, \tilde{w} , \tilde{a}_k 和 $\tilde{\gamma}$ 均为确定最优分类面的参数。在 SVM 中, 使用不同核函数可以构造实现输入空间中不同类型的非线性分类面, 从而得到不同的支持向量算法。常用的核函数有: 多项式核函数:

$$R(u, u_i) = [(u \cdot u_i) + 1]^\sigma$$

径向基（高斯）核函数：

$$(RBF)R(u, u_i) = \exp\left\{-\frac{u - u_i^2}{2\sigma^2}\right\}$$

Sigmoid 核函数：

$$R(u, u_i) = \tanh(\sigma(u \cdot u_i) + C)$$

其中： σ, C 均为参数。

3.2 实验结果与分析

在进行分类实验过程中，SVM 选用径向基核函数，核参数采用交叉验证的方式，将训练样本平均分成 5 组，每次采用其中的 4 组作为训练集对核函数进行训练，剩余 1 组作为测试样本验证模型及参数，最终选择分类性能最好的参数作为最终参数进行分类实验。

表 3 给出了采用不同特征情况下的分类性能，其中 IMF2、IMF3、IMF2+IMF3 表示直接采用 IMF2、IMF3 和 IMF2 与 IMF3 原始信号作为特征向量进行分类的方法，Feature 表示按上述特征提取方法提取 6 维特征作为特征向量进行分类的方法。从表 3 可以看出，对原始信号进行特征提取后再进行分类并没有降低分类性能，相对于直接采用原始信号反而分类性能有所提升，这是由于原始信号中除了对不同运动想象 EEG 信号区分性能较好的信息外还存在大量的冗余信息，这些冗余信息会对分类产生不利的影响。

表 3 不同特征的分类结果

特征	分类器	分类结果(%)
IMF2	SVM	88.31
IMF3	SVM	94.63
IMF2+IMF3	SVM	89.25
Feature	SVM	91.79

表 4 给出了本文所提方法与近年来其它文献中的方法进行对比的结果。其中，文献 [14] 和文献 [6] 都是采用小波包能量进行特征提取，区别在于文献 [14] 是利用的基于马氏距离的线性分类器而文献 [6] 采用的 SVM 分类器，文献 [15] 在文献 [14] 的基础上对 C3、C4 两个通道的脑电信号利用 Burg 算法提取脑电信号的 5 阶 AR 模型系数作为特征并采用线性分类器 (LDA) 获得了 91.43% 的识别结果。从表 4 可以看出，相对于其它方法，本文所提方法可以获得更好的分类结果。

表 4 不同方法的分类结果

特征	分类器	分类结果
文献[11]:WPE	LDA	88.57
文献[12]:WPE	SVM	90.00
文献[13]:WPE+AAR	LDA	91.43
本文:EMD	SVM	94.63

脑电信号除了上述非平稳、非线性外，还存在微弱性的特点，信号幅值通常为 μV 级，很容易受到噪声的污染。

在上述分析的基础上对本文所提方法在不同信噪比情

况下的分类性能进行进一步分析。实验过程中利用 MATLAB 自带的 AWGN () 函数向 EEG 信号中增加不同信噪比的高斯白噪声，信噪比定义如下：

$$SNR = 10 \times \log_{10} \frac{\bar{P}_s}{P_n} = 10 \times \log_{10} \frac{1}{D} \sum_{t=1}^D P_{s(t)} \quad (4)$$

其中： \bar{P}_s 表示信号的平均功率， $P_{s(t)} = |s(t)|^2$ 表示信号中第 t 个元素的功率， P_n 为高斯噪声信号 n 的功率， D 为序列长度。

图 6 给出了不同信噪比情况下本文所提方法的分类性能，可以看出当信噪比高于 25 dB 时，所提方法可以获得 90% 以上的正确分类结果，当信噪比低于 20 dB 时，分类性能急剧下降。图 7 给出了当信噪比为 15 dB 时 EEG 信号的 EMD 分解，可以看出此时 IMF 已完全被噪声污染，无法提取其中的有用信息。因此，在对低信噪比 EEG 信号进行特征提取之前，需要通过噪声抑制方法将噪声分量进行抑制。

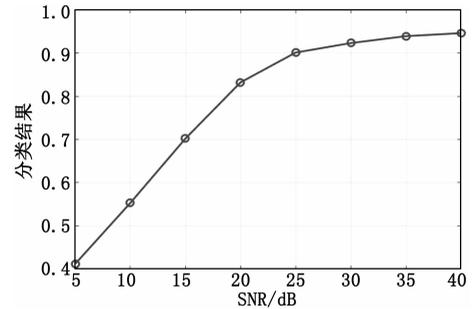


图 6 不同信噪比下的分类性能

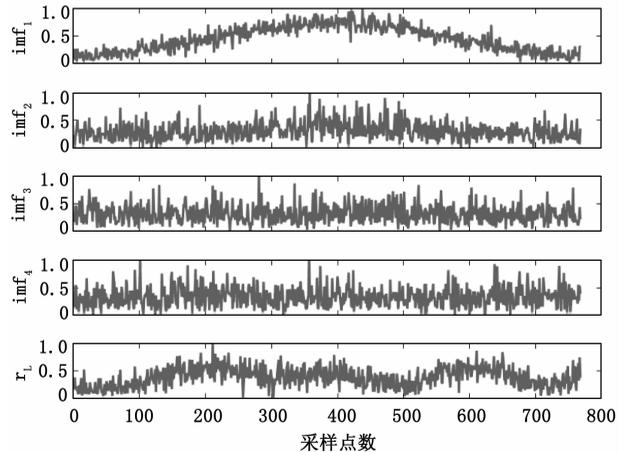


图 7 想象左手运动脑电信号 EMD 分解结果 (SNR=15 dB)

4 总结

脑电信号作为一种复杂的非线性、非平稳信号，如何有效的从脑电信号中提取有用的信息并完成分类识别是当前研究的热点。本文针对运动想象脑电信号的分类问题，提出一种基于 EMD 的特征提取方法，EMD 能够自适应的将脑电信号中包含的节律信息 (α 节律和 β 节律) 分解到不同的 IMF 中，在此基础上提取 6 维特征构成特征向量，在保留对分类有益信息的同时实现对冗余信息的剔除，最后

利用 SVM 对特征向量进行分类可以得到 94.6% 的分类结果, 明显优于其它传统方法。

微弱性作为脑电信号的另一特征, 文末对所提方法在不同信噪比情况下的分类性能进行分析, 指出在低信噪比情况下, 脑电信号受噪声污染严重, 所提方法的分类能力会有明显下降。在接下来的研究工作中, 将进一步对低信噪比条件下的分类方法进行研究, 拓展脑—机接口系统的应用场景。

参考文献:

[1] Pfurtscheller G, Neuper C, Guger C, et al. Current trends in Graz Brain—Computer Interface (BCI) research [J]. IEEE Trans on Rehab Eng, 2000, 8 (2): 216—219.

[2] Wolpaw J R, Birbaumer N, McFarland D J, et al. Brain—computer interfaces for communication and control [J]. Clin Neurophysiol, 2002, 113 (6): 767—791.

[3] Jasmin Kevric, AbdulhamitSubasi. Comparison of signal decomposition methods in classification of EEG signals for motor—imagery BCI system [J]. Biomedical Signal Processing and Control, 2017, 31: 398—406.

[4] 王 宏, 赵海滨, 刘 冲. 采用小波熵和频带能量提取脑电信号特征 [J]. 吉林大学学报: 工学版, 2011, 41 (3): 828—831

[5] 赵海滨, 王 宏. 利用相对小波能量和概率网络的脑—机接口 [J]. 计算机工程与应用, 2009, 45 (5): 26—28

[6] 段锁林, 尚允坤, 潘礼正. 多类运动想象脑电信号特征提取与分类 [J]. 计算机测量与控制, 2016, 24 (2): 283—287.

[7] Burke D P, Kelly S P, de Chazal P, et al. A parametric feature extraction and classification strategy for brain—computer

interfacing [J]. IEEE Trans on Neural Syst Rehabil Eng, 2005, 13 (1): 12—17.

[8] 徐宝国, 宋爱国, 费树岷. 在线脑机接口中脑电信号的特征提取与分类方法 [J]. 电子学报, 2011, 39 (5): 1025—1030.

[9] Anderson C W, Stolz E A, Shamsunder S. Multivariate autoregressive models for classification of spontaneous electroencephalographic signals during mental tasks [J]. IEEE Trans on Biomed Eng, 1998, 45 (3): 277—286.

[10] Yildiz A, Akin M, Poyraz M, et al. Application of adaptive neuro—fuzzy inference system for vigilance level estimation by using wavelet entropy feature extraction [J]. Expert Syst Appl, 2009, 36 (4): 7390—7399.

[11] Tipping M E, Bishop C M. Probabilistic principle component analysis [J]. Journal of royal statistical society, 1999, 61 (3): 611—622.

[12] Huang N E, Shen Z, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non—stationary time series analysis [J]. Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences 454 (1971), (8 March 1998) 903—995.

[13] Flandrin P, Rilling G, Goncalves P. Empirical mode decomposition as a filter bank, IEEE Signal Processing Letters [J]. 2004, 11 (2): 112—114.

[14] 徐宝国, 宋爱国. 基于小波包变换和聚类分析的脑电信号识别方法 [J]. 仪器仪表学报, 2009, 30 (1): 25—28.

[15] 王艳景, 乔晓艳, 李 鹏, 等. 基于小波包熵和支持向量机的运动想象任务分类研究 [J]. 仪器仪表学报, 2010, 31 (12): 2729—2735.

..... (上接第 188 页)

参考文献:

[1] 卢 波. 世界月球探测的发展回顾与展望 [J]. 国际太空, 2019, 1 (481): 12—18.

[2] Jun' ichiro Kawaguchi, Tatsuaki Hashimoto, Takashi Kubota, Shujiro Sawai. Autonomous optical guidance and navigation strategy around a small body [J]. Journal of Guidance, Control, and Dynamics, 1997, 20 (5): 1010—1017.

[3] Li Jianguo, Cui Hutao. Vision—aided inertial navigation for pin—point landing on Mars [A]. The 2nd International Conference on Intelligent Control and Information Processing [C]. 2011: 14—18.

[4] Han Hongshuo, Chen Jie. 21st century foreign deep space exploration development plans and their progress [J]. Spacecraft Engineering, 2008, 17 (3): 1—22.

[5] 李俊峰, 崔 文, 宝音贺西. 深空探测自主导航技术综述 [J]. 力学与实践, 2012, 34 (2): 1—9.

[6] 吴伟仁, 王大轶, 李 骥, 等. 月球软着陆避障段定点着陆导航方法研究. 中国科学 [J]. 2011, 41 (9): 1054—1063.

[7] 李竹良, 赵宇明. 基于单幅图片的相机完全标定 [J]. 计算机工程, 2013, 39: 1—5.

[8] 于真真, 侯 霞, 周翠芸. 星载激光测高技术发展现状 [J]. 中国激光, 2013, 50: 1—10.

[9] 赵一鸣, 李艳华, 高雅楠, 等. 激光雷达的应用及发展趋势 [J]. 遥测遥控, 2014, 35 (5): 4—21.

[10] 彭晓东, 刘 波, 孟 新, 等. 星载可见光相机成像仿真建模分析 [J]. 光子学报, 2011, 40 (7): 1106—1111.

[11] 姜 斌, 石 峰, 崔东旭. 改进的 K 均值聚类红外目标检测方法 [J]. 应用光学, 2012, 33 (4): 766—769.

[12] 朱德海. 点云库 PCL 学习教程 [M]. 北京: 北京航空航天大学出版社, 2012.

[13] 吴文升, 何 军, 刘 祎, 等. 机载激光雷达系统高精度点云生成研究 [J]. 计算机测量与控制, 2012 (4): 1088—1094.

[14] 闫 利, 谢 洪, 胡晓斌, 等. 一种新的点云平面混合分割方法 [J]. 武汉大学学报 (信息科学版), 2013, 38 (5): 517—521.

[15] 曾齐红, 毛建华, 李先华, 等. 激光雷达点云平面拟合过滤算法 [J]. 武汉大学学报 (信息科学版), 2008, 33 (1): 24—28.

[16] 张洪华, 梁 俊, 黄翔宇, 等. 嫦娥三号自主避障软着陆控制技术 [J]. 中国科学, 2014, 44 (6): 559—568.

[17] 张洪华, 关轶峰, 黄翔宇, 等. 嫦娥三号着陆器动力下降段的制导导航与控制 [J]. 中国科学, 2014, 44 (4): 377—384.

[18] 王大轶, 李 骥, 黄翔宇, 等. 月球着陆过程高精度自主导航避障方法 [J]. 深空探测学报, 2014, 1 (1): 44—51.