

DOI: 10.19650/j.cnki.cjsi.J2006187

基于变分模态分解的脑电锁相刺激方法*

陈 妮^{1,2}, 覃玉荣³, 熊艳婷³, 李卓然³

(1. 广西大学电气工程学院 南宁 530004; 2 广西医科大学生物医学工程系 南宁 530021;
3. 广西大学计算机与电子信息学院 南宁 530004)

摘 要:锁相刺激技术在神经机制研究及临床治疗中具有很好的应用前景,但需解决脑电信号(EEG)和刺激信号之间相位锁定的问题。由于 EEG 复杂的时变性,目前还缺乏用于实现与 EEG 锁相的有效刺激算法。为此,提出基于变分模态分解(VMD)和自回归(AR)预测的锁相刺激方法。首先对采集的 EEG 进行 VMD 处理,得到多个本征模态信号;然后对每个本征模态信号采用 AR 模型进行预测,将所有模态对应的预测值叠加;最后依据叠加结果的频率和相位特征,生成与 EEG 锁相的刺激。分别对模拟 EEG 和 20 名受试者(年龄 20~36 岁,男性 12 名,女性 8 名)的睁、闭眼静息态 EEG 进行测试。结果表明,VMD-AR 方法能很好地克服 EEG 非平稳性的影响而生成具有更高锁相值(PLV)的刺激;预测时长从 0.01 s 增大至 0.4 s 时,睁眼 EEG 的 PLV 从 0.99 减小至 0.39,闭眼 EEG 的 PLV 从 0.99 减小至 0.65;建模时长从 0.25 s 增大至 2.5 s 时,睁眼 EEG 的 PLV 从 0.64 增大至 0.83,闭眼 EEG 的 PLV 从 0.53 增大至 0.65;在所有测试条件下,VMD-AR 方法的锁相性能均优于 AR 和基于经验模态分解的 AR 方法 EMD-AR。该方法同样适用于其他非平稳信号的闭环锁相系统。

关键词:变分模态分解;自回归模型;脑电;锁相刺激

中图分类号: TN98 TH89 **文献标识码:** A **国家标准学科分类代码:** 310.61

Phase locked stimulus method of EEG based on variational mode decomposition

Chen Ni^{1,2}, Qin Yurong³, Xiong Yanting³, Li Zhuoran³

(1. College of Electrical Engineering, Guangxi University, Nanning 530004, China;

2. Department of Biomedical Engineering, Guangxi Medical University, Nanning 530021, China;

3. College of Computer and Electronic Information, Guangxi University, Nanning 530004, China)

Abstract:The phase locked stimulus technology has great application prospect in the neural mechanism research and clinical treatment. However, the problem of phase locked between electroencephalogram (EEG) and stimulus need to be solved. Due to the complicated time-varying characteristics of EEG, there is still lack of effective stimulus algorithms that can be used to lock with the EEG phase. Therefore, a phase locked stimulus method for EEG is proposed, which is based on the variational mode decomposition (VMD) and autoregressive (AR) prediction. Firstly, EEG is processed by VMD to obtain multiple eigenmode signals. Then, each eigenmode signal is predicted by the AR model. The predicted values corresponding to all modes are accumulated. Finally, according to the frequency and phase characteristics of the accumulated results, the stimulus is generated, which is phase-locked with EEG. The method is evaluated in the synthesized EEG and 20 subjects (aged 20~36, male 12, female 8) offline resting EEG respectively. Results show that VMD-AR can overcome the influence of EEG instability and generate the stimulus with higher phase-locked value (PLV). When the length of prediction time increases from 0.01 s to 0.4 s, PLV of opened EEG decreases from 0.99 to 0.39, and PLV of closed EEG decreases from 0.99 to 0.65. When the length of modeling time increases from 0.25 s to 2.5 s, PLV of opened EEG increases from 0.64 to 0.83, and PLV of closed EEG increases from 0.53 to 0.65. The phase locked performance of VMD-AR is superior to the methods of AR and AR based on empirical mode decomposition EMD-AR under all test conditions. This method can also be applied to other non-stationary closed-loop phase-locked systems.

Keywords:variational mode decomposition; autoregressive model; electroencephalogram; phase locked stimulus

收稿日期:2020-03-18 Received Date:2020-03-18

* 基金项目:广西自然科学基金(2016GXNSFAA380068)项目资助

0 引言

锁相刺激是一类依据实时采集的脑电 (electroencephalogram, EEG) 特征来生成刺激信号, 从而使输出的 EEG 与刺激具有相位锁定关系的神经调节技术。该技术在神经系统工作机制研究和神经精神疾病治疗等领域具有很好的应用前景^[1-4]。

在光、电或磁刺激的研究中发现: 正弦刺激能够同步频率相近的神经振荡, 通过锁相效应对大脑的感知认知活动形成干预^[5-6]; 脉冲刺激出现在 EEG 或局部场电位 (local field potential, LFP) 的不同相位时, 可以产生兴奋性或抑制性的神经调节效果^[7-9]。还有研究发现: 经颅交流电或磁刺激 (repetitive transcranial magnetic stimulation/transcranial electric stimulation, rTMS/TES) 治疗神经精神疾病时存在个体间效应异质性问题, 其可能原因是刺激与内在大脑活动之间的锁相程度是变化的^[10-11]。这些研究结果表明, 外刺激需要与输出 EEG 保持稳定的相位锁定关系才能有效地调节神经振荡活动。

锁相刺激信号需要依据下一时段 EEG 的频率或相位特征来生成。而下一时段的 EEG 是由当前采集到的信号预测得到。已经提出基于快速傅里叶变换 (fast Fourier transform, FFT) 或自回归 (autoregressive, AR) 模型的 EEG 预测方法^[12-14]。两种方法均要求 EEG 为平稳信号且频谱具有窄带功率峰值特征。然而, EEG 在大多数情况下是一种时变、非平稳信号。此时, 由 FFT 或 AR 方法生成的刺激与 EEG 之间的锁相程度会降低, 从而影响刺激对神经振荡活动的调节效果。

有效的神经振荡调节需要刺激与输出 EEG 之间具有高的锁相值。目前, 关于如何提高锁相值的研究仍较少。为此, 本文提出基于变分模态分解 (variational mode decomposition, VMD) 和 AR 预测的锁相刺激方法 (VMD-AR 方法)。该方法首先利用 VMD 分解得到 EEG 的多个本征模态分量, 再对各模态分量进行 AR 建模及预测; 然后利用多个模态分量的预测值重构得到预测 EEG; 最后依据预测 EEG 的特征生成刺激。在不同预测时长、建模时长和噪声强度下, 进行 VMD-AR 方法的性能测试。结果表明, 所提出方法的锁相性能要优于 AR、EMD-AR 方法, 并且在 EEG 非平稳性增大时能获得更高的锁相值。

1 理论分析

1.1 VMD-AR 方法的分析

经验模态分解 (empirical mode decomposition, EMD) 和集合经验模态分解 (ensemble empirical mode decomposition, EEMD) 已在癫痫脑电或运动脑电的特征

分析中获得应用^[15-16]。实际应用中, EMD 方法易出现模态混叠, 不能有效分离频率相近的信号成分; EEMD 方法虽然可以改善模态混叠问题, 但计算量大且有可能分解得到的分量个数超过实际的个数^[17]。VMD 是一种频域分离方法, 具有自适应调节各模态分量中心频率和带宽的优势, 能够有效分解频率相近的信号^[18-19]。锁相刺激中的 EEG 通常为窄带信号, 各模态分量的频率主要集中在某一频段范围内。因此, VMD 方法更适用于锁相刺激 EEG 的分解。

VMD-AR 方法的核心是通过多模态分解减小 EEG 的非平稳性, 从而提高 AR 模型的预测精度, 进一步生成锁相值更高的刺激信号。该方法主要涉及: 1) EEG 的窄带滤波; 2) 窄带 EEG 的 VMD 分解; 3) AR 建模及预测; 4) 根据预测 EEG 特征生成刺激。

1.2 EEG 的窄带滤波

为获取感兴趣频段的信号, 需要对原始采集的 EEG 进行窄带滤波。考虑到不同受试者在特定频带的脑电中心频率存在差异, 且同一受试者在一段较长时间内脑电中心频率也会发生偏移^[20], 滤波带宽根据实时采集的 EEG 来设置。窄带滤波的实现过程为: 对一定时间窗长的 EEG 进行 FFT 计算, 计算感兴趣频段的峰值功率, 以峰值功率频点作为窄带滤波的中心频率 f_{center} , 取 $f_{\text{center}} \pm 2$ Hz 作为 FIR 带通滤波器的截止频率。

1.3 VMD 分解原理

VMD 算法是将原始信号 $f(t)$ 分解成 k 个中心频率为 ω_k 的模态函数 u_k 。模态函数 u_k 被定义为一个调幅调频信号, 记为:

$$u_k(t) = A_k(t) \cdot \cos(\varphi_k(t)) \quad (1)$$

式中: $A_k(t)$ 为瞬时幅值; $\varphi_k(t)$ 为相位。 $\varphi_k(t)$ 为非递减函数; $\varphi'_k(t) \geq 0$; 包络线非负, $A_k(t) \geq 0$; 并且包络 $A_k(t)$ 和瞬时频率 $\omega_k(t) = \varphi'_k(t)$ 对于相位 $\varphi_k(t)$ 来说是缓变的。

VMD 的整体框架是一个变分问题, 可使每个模态的估计带宽之和最小。为估计模态 u_k 的带宽, 首先通过希尔伯特变换 (Hilbert transform, HT) 得到每个模态 u_k 的单边频谱; 然后对各模态解析信号混合一预估中心频率, 将每个模态的频谱调制到相应的基频带; 再计算解析信号梯度的平方范数, 估计出模态 u_k 的带宽。所产生的约束变分问题如下:

$$\left\{ \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \left[\delta(t) + \frac{j}{\pi t} \right] * u_k(t) \right\| \cdot e^{-j\omega_k t} \right\|_2^2 \right\} \right\} \quad (2)$$

$$\text{s.t. } \sum_k u_k(t) = f(t)$$

式中: $\{u_k\} = \{u_1, u_2, \dots, u_k\}$ 和 $\{\omega_k\} = \{\omega_1, \omega_2, \dots,$

ω_k 分别为分解的 k 个模态及其对应中心频率的集合; “ $*$ ”表示卷积运算; ∂_t 表示梯度运算。

为求解式(2)的约束变分问题,引入二次惩罚参数 α 和拉格朗日乘法算子 $\lambda(t)$, 将约束变分问题转化为非约束变分问题。增广拉格朗日函数如下:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] \cdot e^{-j\omega t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \quad (3)$$

式中: $\langle \cdot \rangle$ 表示内积运算。用交替方向乘数法迭代更新 u_k, ω_k 及 λ , 求解式(3)增广拉格朗日函数的鞍点,即约束变分模型的最优解。

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i^n(\omega) + \frac{\hat{\lambda}^n(\omega)}{2}}{1 + 2\alpha \cdot (\omega - \omega_k^n)^2} \quad (4)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega \cdot |\hat{u}_k^n(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^n(\omega)|^2 d\omega} \quad (5)$$

式中: $\hat{f}(\omega), \hat{u}_i^n(\omega), \hat{\lambda}^n(\omega)$ 和 $\hat{u}_k^{n+1}(\omega)$ 分别表示 $f(t), u_i^n(t), \lambda^n(t)$ 和 $u_k^{n+1}(t)$ 的傅里叶变换; n 是迭代次数。

$$u_k(t) = Real\{F^{-1}[\hat{u}_k(\omega)]\} \quad (6)$$

式中: $F^{-1}(\cdot)$ 表示傅里叶逆变换; $Real(\cdot)$ 表示复数的实部。

VMD将原始信号 $f(t)$ 分解为 k 个模态分量的具体步骤如下:

- 1) 初始化 $\{u_k^t\}, \{\omega_k^t\}, \lambda^1$ 和 n 为 0;
- 2) 由式(4)和(5)分别迭代更新 \hat{u}_k 和 ω_k ;
- 3) 根据式(6)更新 $\hat{\lambda}$;

$$\hat{\lambda}^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + \tau \left[\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right] \quad (7)$$

- 4) 重复步骤 2)~3), 直至满足迭代终止条件:

$$\sum_k \left\| \hat{u}_k^{n+1} - \hat{u}_k^n \right\|_2^2 / \left\| \hat{u}_k^n \right\|_2^2 < \varepsilon \quad (8)$$

其中, ε 为判别精度, $\varepsilon > 0$ 。

- 5) 输出结果, 得到 k 个模态分量。

1.4 自回归 AR 建模

AR建模的原理为:假设观测序列可表示为平稳信号与白噪声的叠加,则序列 $\{x_i\}$ 中第 i 个 x 值与前 p 个 x 值之间的关系可表示为:

$$x_i = a_1 \cdot x_{i-1} + a_2 \cdot x_{i-2} + a_3 \cdot x_{i-3} + \dots + a_p \cdot x_{i-p} + \varepsilon_i \quad (9)$$

式中: $a_1, a_2, a_3, \dots, a_p$ 为自回归模型系数; p 为 AR 模型阶数; ε_i 表示 AR 模型残差, 是均值为 0、方差为 σ^2 的白噪声序列。

常用的 AR 模型系数估计方法有: Yule-Walker 法、最小二乘法、Burg 法等。本文采用 Yule-Walker 法估计 AR 模型系数, 根据 AIC 准则确定 AR 模型阶数, 建模时长为待处理数据长度的 1/4。

1.5 VMD-AR 方法的实现

VMD-AR 方法生成锁相刺激的具体实现步骤为:

- 1) 对 EEG 进行多模态分解

(1) 对原始 EEG 信号 X 进行 FFT 计算, 根据选定频带的功率峰值确定带通滤波器参数。

(2) 采用巴特沃斯带通滤波器对 X 进行滤波, 得到滤波后的 EEG 信号 X_f 。

(3) VMD 参数初始化, 包括模态个数 k 、噪声容限度 τ 和惩罚因子 α 。对 X_f 进行 VMD 分解。

(4) VMD 分解后得到 k 个 IMF 分量, 判断 k 个 IMF 分量的最大中心频率是否大于 40 Hz。若 ≤ 40 Hz, 则 $k = k + 1$, 跳转至步骤(4), 再次进行 VMD 分解; 若 > 40 Hz, 则 $k = k - 1$, 往下执行。通常认为 EEG 的有效成分集中在小于 40 Hz 的频谱范围内, 因此设置 IMF 中心频率的分解阈值为 40 Hz。

- 2) 用 AR 模型预测下一时段的 EEG

- (1) 对 k 个 IMF 分量分别进行 AR 建模。

(2) 利用所建模型对 k 个 IMF 分量做一步预测, 得到 k 个预测值 x_1, x_2, \dots, x_k 。利用 k 个预测值更新 k 个 AR 模型的计算数据, 进行下一步预测, 直至完成 n 步数据预测。

(3) 将 k 个分量的预测值进行重构叠加, 得到 X_f 的预测序列 X_p , 即: $X_p = X_{p1} + X_{p2} + \dots + X_{pk}$ 。

- 3) 生成锁相刺激信号

- (1) 采用 HT 计算 X_p 的相位和频率。

(2) 对于脉冲刺激, 判断预设的刺激相位在 X_p 中的时间位置, 由延时控制脉冲刺激输出。

(3) 对于正弦刺激, 则控制刺激器输出与 X_p 同初相、同主频的正弦刺激信号。

2 实验数据来源

α 频段的脑电波在认知研究中起着重要作用, 是目前最受关注的神经振荡调节目标。因此, 选取静息态 EEG 的 α 频段信号进行算法性能测试。测试数据由本实验室采集获得。为了解噪声强度变化对算法性能的影响, 通过生成模拟数据来进行测试。

2.1 离线数据采集

采集受试者睁、闭眼的静息态 EEG, 实验方案如下:

受试对象: 20 名 (男性 12 名, 女性 8 名), 年龄 20~36 岁, 志愿参与实验, 裸眼或矫正后视力正常, 个人及家

族无精神病史和癫痫病史,实验前签署知情同意书。

实验环境及平台:实验在黑暗、安静的室内进行,室内温度控制在26℃。实验系统包括 Neuroscan 32 导脑电放大器 and 上位机采集软件,系统连接如图1所示。系统采样率为1 kHz,带通滤波范围为0.5~35 Hz。

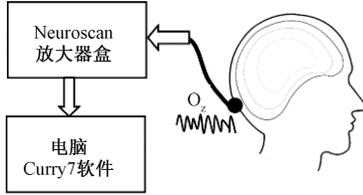


图1 EEG采集系统

Fig.1 EEG acquisition system

EEG采集:受试者坐在舒适的椅子上,保持清醒、放松状态。按照10~20系统标准放置32导脑电电极,以AFz作为参考点。在电脑端通过Curry7软件记录受试者的睁、闭眼EEG,记录时长为1 min。取Oz通道的EEG用于算法测试。

2.2 模拟数据生成

选取1名受试者的睁眼EEG,人为叠加不同幅度的高斯噪声,生成不同信噪比(signal-noise ratio, SNR)的模拟EEG,用于测试噪声对VMD-AR方法性能的影响。模拟EEG的计算公式为:

$$X(t) = U_{Sm} \cdot EEG_{rest}(t) + U_{Nm} \cdot wagn(t) \quad (10)$$

式中: t 代表时间; U_{Sm} 是静息态EEG的幅值; U_{Nm} 是噪声幅值; $wagn(t)$ 代表高斯噪声。在 $X(t)$ 中改变噪声强度 U_{Nm} 得到不同SNR的模拟信号,用于验证噪声对算法性能的影响。对 $EEG_{rest}(t)$ 和 $wagn(t)$ 进行最大值归一化处理,以便于二者相加合成模拟数据。

SNR的计算公式为:

$$SNR = 20 \lg \left(\frac{U_S}{U_N} \right) \quad (11)$$

式中: U_S 和 U_N 分别是原始信号和噪声信号的有效幅度值。

3 实验测试

本节首先进行VMD-AR方法的验证;然后改变预测时长和建模时长,测试两个计算参数变化对结果的影响,并与AR、EMD-AR方法的计算结果进行比较;采用单因素方差分析,观察3种方法的锁相性能在受试者中是否存在显著性差异;最后,通过模拟EEG测试噪声强度对算法性能的影响。

3.1 评估指标

对EEG的准确预测是生成锁相刺激信号的关键。

本文分别从预测精度和锁相程度进行方法的性能评估。采用绝对误差(absolute error, AE)、平均绝对误差(mean average error, MAE)和平均均方根误差(root mean square error, RMSE)评估方法的预测精度;通过相位误差(phase error, PhE)和平均相位误差(mean phase error, MPhE)、锁相指数(phase locked value, PLV)评估方法的锁相性能。

$$AE_i = (\hat{y}_i - y_i) \quad (12)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (13)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (14)$$

$$PhE_i = (\hat{\phi}_i - \phi_i) \quad (15)$$

$$MPhE = \frac{1}{n} \sum_{i=1}^n |\hat{\phi}_i - \phi_i| \quad (16)$$

$$PLV = \frac{1}{n} \sum_{i=1}^n e^{j(PhE_i)} \quad (17)$$

式中: \hat{y}_i 是EEG的预测值; y_i 是EEG的真实值; $\hat{\phi}_i$ 是预测EEG的相位; ϕ_i 是真实EEG的相位;下标 i 代表时间序列点, $i=1, 2, \dots, n$;PLV表征EEG预测值和真实值之间相位差的稳定程度,PLV越大代表两组数据之间的锁相性能越好。式(15)~(17)中的相位由HT计算得到。参照文献[10、14]的方法,用预测EEG与真实EEG的MPhE和PLV来衡量算法的锁相性能。

3.2 测试结果及分析

1) VMD-AR方法的验证

对1名受试者3 s时长的睁眼EEG进行窄带滤波后,剔除前0.2 s,余下2.8 s的数据。从2.8 s的数据中取前0.7 s用于AR建模(建模时长为待处理数据长度的1/4,以下计算相同)。预测时长为0.2 s。各部分的计算结果如图2所示。为显示清晰,仅展示1 s的结果。

EEG经过EMD和VMD分解后得到多个本征模态分量,对多个模态分量进行叠加就得到重构信号。图2(a)所示为滤波EEG和由EMD、VMD得到的重构EEG波形。可以看到,重构EEG与滤波EEG基本吻合。说明两种方法分解出的多模态分量均能很好地还原原信号,后续可以采用这两种方法进行EEG分解。

图2(b)~(c)所示分别为预测EEG与真实EEG的波形比较及相位比较。从图2(b)可知,尽管预测波形与真实波形存在一定偏差,但基本能跟随真实波形的变化。在图2(c)中观察到预测相位和真实相位也存在类似的变化关系。图2(c)中的圆圈代表在 π 相位处生成刺激的时间点。可以发现,刺激点有一部分落在真实的 π 相位处,有一部分则与真实的 π 相位存在一定偏差。这种偏差是由于预测波形的误差而引起的,这将导致刺激与

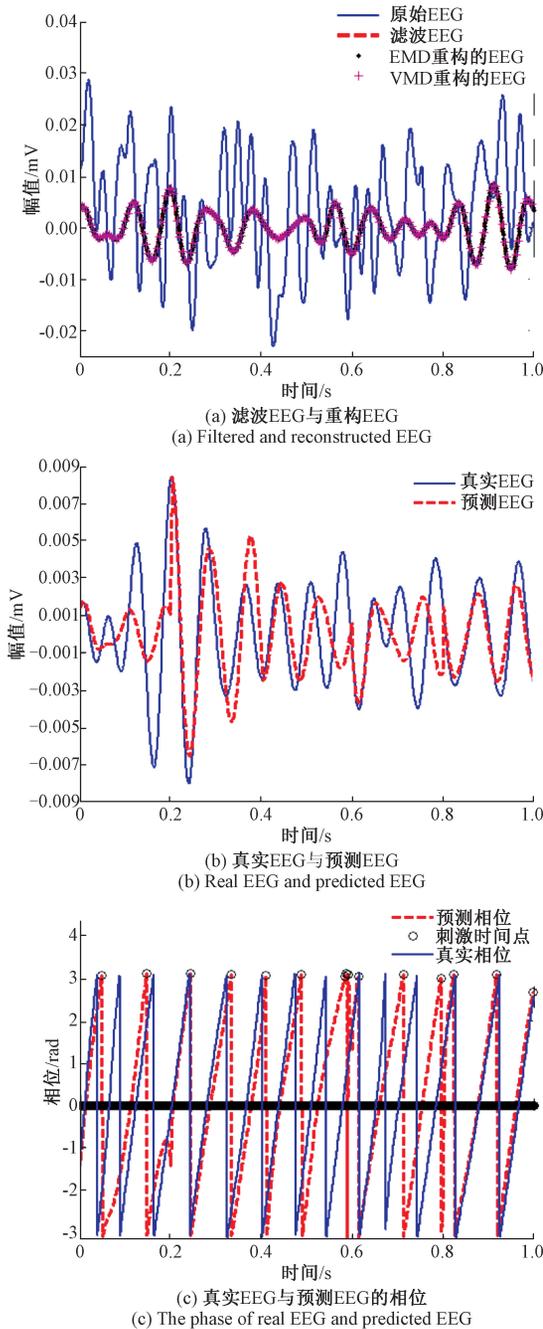


图 2 VMD-AR 方法各计算部分的结果
Fig.2 Calculation results of each part of the VMD-AR method

EEG 之间不能很好地实现锁相。由此可见,锁相性能与算法的预测精度密切相关。

影响算法预测精度的计算参数有预测时长和建模时长。接下来将测试不同计算参数下 VMD-AR 方法的预测精度和锁相程度,并与 AR、EMD-AR 方法的计算结果进行比较。

2) 不同预测时长的方法测试及比较

分别采用 AR、EMD-AR 和 VMD-AR 3 种方法对

20 名受试者的睁、闭眼 EEG 进行锁相计算。

预测时长分别取 0.01、0.05、0.1、0.15、0.2、0.25、0.3、0.35、0.4 s,对 20 名受试者的睁、闭眼 EEG(数据长度为 3 s)进行预测精度和锁相程度的计算。不同预测时长下的计算结果为 20 名受试者计算结果的平均,如图 3 和 4 所示。

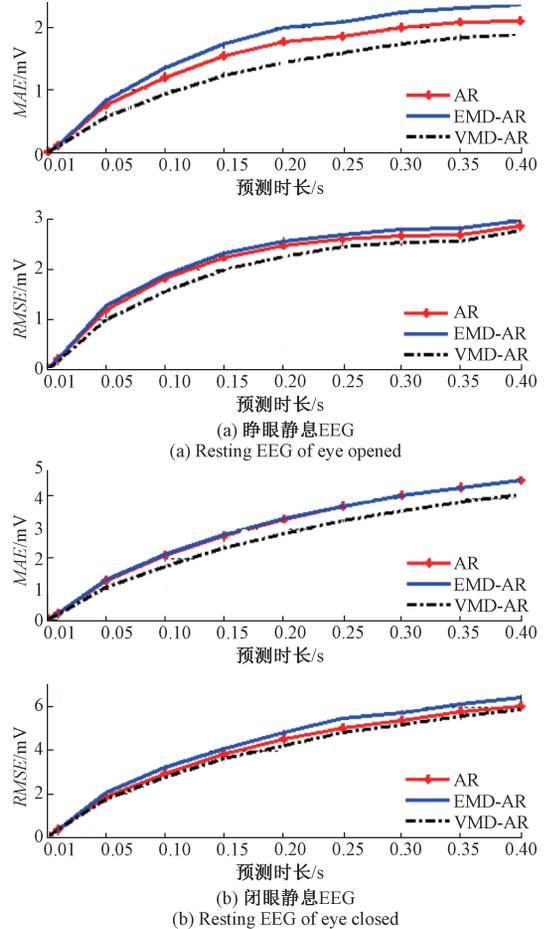


图 3 不同预测时长下,AR、EMD-AR 和 VMD-AR 的预测性能比较

Fig.3 Comparison of predictive performance of AR, EMD-AR and VMD-AR under different prediction time lengths

由图 3 可知,对于睁、闭眼 EEG,AR、EMD-AR 和 VMD-AR 3 种方法的 MAE、RMSE 值均随着预测步长的增大而增大,但 VMD-AR 方法的这两项误差指标均小于其他两种方法。

由图 4 可知,预测时长与锁相性能的变化关系近似为线性关系。对于睁、闭眼 EEG,AR、EMD-AR 和 VMD-AR 3 种方法的 MP_{hE} 值均随预测时长的增大而增大, PLV 值随预测时长的增大而减小。这是由于预测误差会随着预测时长的增大而不断累加增大,从而引起相位误差的增大,进一步造成锁相性能的下降。在所有预测时长下,VMD-AR 方法的 PLV 值均高于其他两种方法,说明该方法具有更好的锁相性能。

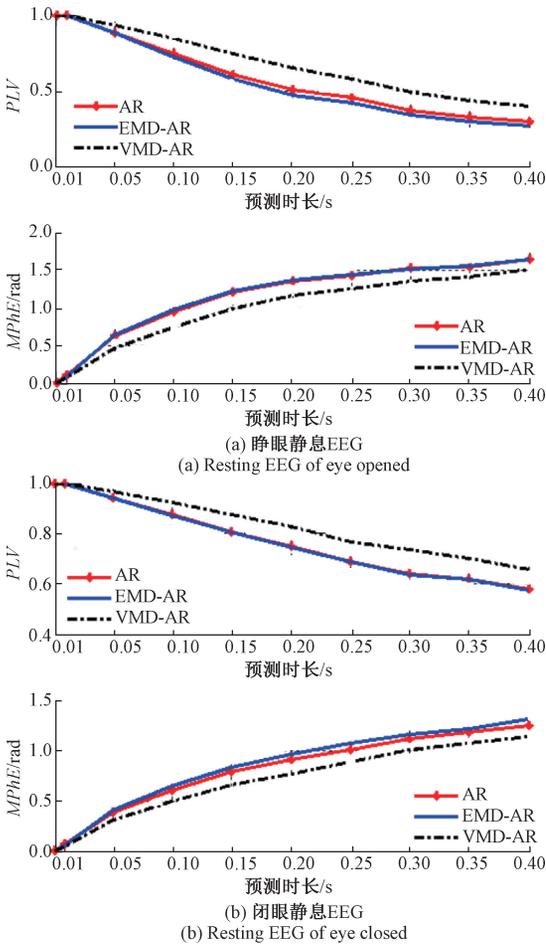


图4 不同预测时长下,AR,EMD-AR和VMD-AR的锁相性能比较

Fig.4 Comparison of phase-locked performance of AR, EMD-AR and VMD-AR under different prediction time lengths

进一步,对 $MphE$ 和 PLV 进行单因素方差分析,探讨不同预测时长下3种方法的锁相程度在20名受试者中是否存在显著性差异。计算得到的 p 值如表1所示。

表1 不同预测时长的 p 值

Table 1 The p -values of different predicting time lengths

预测时长/s	睁眼 $MphE$	闭眼 $MphE$	睁眼 PLV	闭眼 PLV
0.001	0.836	0.762	0.413	0.766
0.010	0.494	0.684	0.451	0.997
0.050	0.014	0.021	0.014	0.045
0.100	0.012	0.012	0.023	0.029
0.150	0.008	0.015	0.054	0.024
0.200	0.071	0.024	0.015	0.040
0.250	0.011	0.014	0.040	0.022
0.300	0.012	0.033	0.026	0.027
0.350	0.019	0.006	0.027	0.011
0.400	0.003	0.008	0.012	0.022

$P < 0.05$ 时,认为3种方法的 $MphE$ 和 PLV 具有显著性差异。从表1可以看到,对于睁、闭眼 EEG,在预测时长小于 0.05 s 时, $P > 0.05$,3种方法的锁相程度在受试者中不具有显著性差异。但随着预测时长的增加, $P < 0.05$,3种方法的显著性差异明显体现出来。由此说明,在较大的预测时长下,VMD-AR方法的锁相性能显著优于其他两种方法。

3) 不同建模时长的方法测试及比较

EEG的非平稳性会随着数据时长的增大而增大,从而导致AR模型预测精度的降低。通过改变建模时长获取不同平稳性的EEG,测试数据非平稳性变化对方法锁相性能的影响。

取0.25~2.5 s作为建模时长,时长间隔为0.25 s,预测时长为0.2 s。不同建模时长下的计算结果为20名受试者计算结果的平均,如图5和6所示。

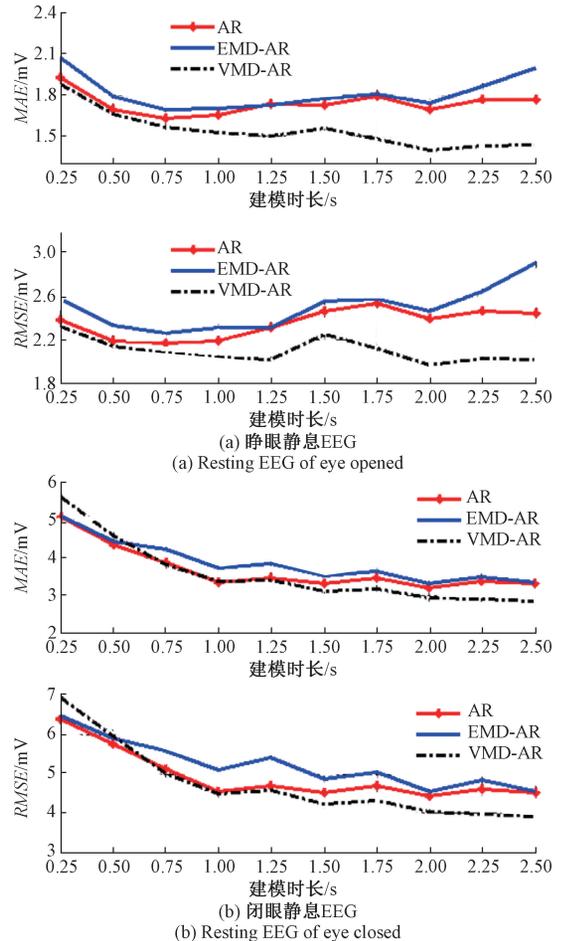


图5 不同建模时长下,AR,EMD-AR和VMD-AR的预测性能比较

Fig.5 Comparison of predictive performance of AR, EMD-AR and VMD-AR under different modeling time lengths

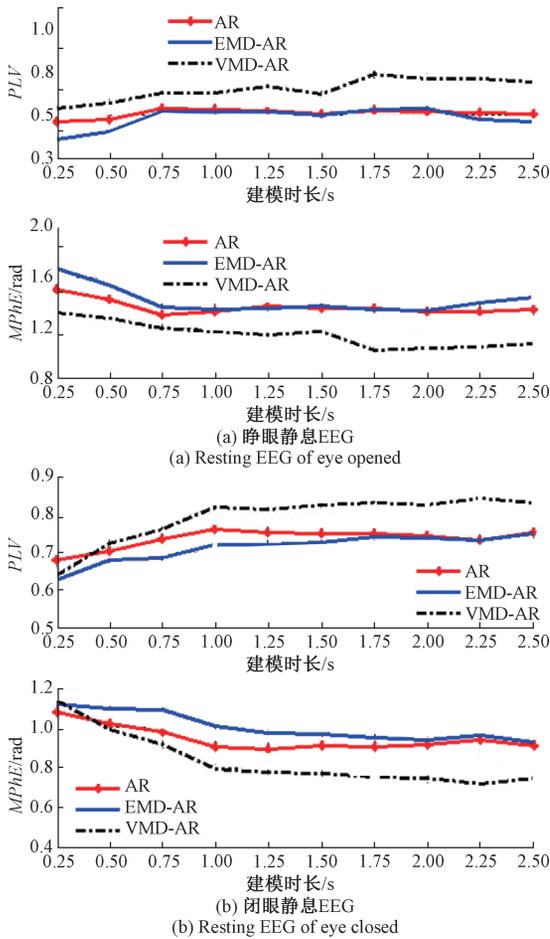


图 6 不同建模时长下,AR、EMD-AR 和 VMD-AR 的锁相性能比较

Fig.6 Comparison of phase-locked performance of AR, EMD-AR and VMD-AR under different modeling time lengths

由图 5 可知,随着建模时长的增加,对于睁眼 EEG, AR 和 EMD-AR 方法的 MAE 和 RMSE 先减小后增大;对于闭眼 EEG,则是逐渐减小。VMD-AR 方法对于睁、闭眼 EEG,两项误差指标均随着建模时长的增加而减小。

由图 6 可知,建模时长与锁相性能的变化关系是非线性的。(1)对于 AR 和 EMD-AR 方法,建模时长小于 0.75 s(睁眼 EEG)或 1 s(闭眼 EEG)时,PLV 随建模时长的增大而增大,MPHE 随建模时长的增大而减小。这是因为适当的增加建模数据量可以获得更精确的预测模型,提高锁相程度。建模时长继续增大,MPHE 和 PLV 近似不变。

(2)对于 VMD-AR 方法,随建模时长的增加,MPHE 减小而 PLV 增大。由此说明 VMD-AR 方法对于非平稳信号具有更好的锁相性能。无论是睁眼 EEG 还是闭眼 EEG,VMD-AR 方法的锁相性能均优于其他两种方法。

进一步,对 MphE 和 PLV 进行单因素方差分析,探讨

不同建模时长下 3 种方法的锁相程度在受试者中是否存在显著性差异。计算得到的 p 值如表 2 所示。

表 2 不同建模时长的 p 值

Table 2 The p -value of different modeling time lengths

建模时长/s	睁眼 MphE	闭眼 MphE	睁眼 PLV	闭眼 PLV
0.25	0.027	0.886	0.013	0.686
0.50	0.004	0.266	0.030	0.513
0.75	0.007	0.024	0.014	0.040
1.00	0.006	0.046	0.015	0.016
1.25	0.012	0.036	0.027	0.012
1.50	0.016	0.018	0.049	0.047
1.75	2.4×10^{-5}	0.048	2.1×10^{-4}	0.009
2.00	9.0×10^{-4}	0.050	0.004	0.008
2.25	3.8×10^{-6}	0.017	1.2×10^{-5}	0.018
2.50	1.7×10^{-6}	0.039	5.4×10^{-6}	0.009

从表 2 可知,对于睁眼 EEG, MphE 和 PLV 的 p 值均大于 0.05,3 种方法的锁相程度存在显著性差异。对于闭眼 EEG,建模时长小于 0.75 s 时, $P > 0.05$;但随着建模时长的增加, p 值均小于 0.05。说明 3 种方法对闭眼 EEG 的锁相程度在建模时长较长时存在显著性差异。表 2 结果表明,在建模时长较大时,VMD-AR 方法的锁相性能优于其他两种方法。

4) 噪声对 VMD-AR 锁相性能的影响

实际测量的 EEG 信号不可避免地混杂有噪声。为了解噪声变化对 VMD-AR 锁相性能的影响,由式(16)生成 SNR 分别为 0、-4、-8、-12、-16、-20 dB 的模拟 EEG,模拟 EEG 的采样率为 1 000 Hz,时长为 3 s。计算 MAE、RMSE、MPhE 和 PLV,结果如表 3 所示。

表 3 不同 SNR 的指标比较

Table 3 Comparison of evaluation indexes under different SNR

SNR/dB	MAE/mV	RMSE/mV	MPhE/rad	PLV
0	0.013 6	0.019 9	0.500 7	0.916 4
-4	0.017 0	0.025 5	0.514 7	0.907 1
-8	0.028 5	0.039 8	0.571 6	0.901 4
-12	0.039 8	0.055 3	0.839 1	0.801 6
-16	0.067 8	0.092 1	0.902 4	0.717 2
-20	0.107 5	0.145 1	0.981 5	0.702 2

由表 3 可知,随着噪声强度的增加,MAE、RMSE 和 MPhE 呈上升趋势,PLV 逐渐减小。最小 $PLV = 0.702 2$,表明即使在噪声干扰较大($SNR = -20$ dB)的情况下,

VMD-AR 方法仍具有较高的锁相值。

4 结 论

EEG 属于非平稳、时变信号。然而,目前基于 AR 预测的锁相刺激技术只能有效用于输出 EEG 信号具有平稳、窄带功率峰值特征的系统。为此,本文基于 VMD 分解技术,提出了一种提高锁相刺激系统 *PLV* 值的新方法—VMD-AR 算法。对睁、闭眼 EEG 的测试结果表明,VMD-AR 方法的锁相性能要优于 AR 和 EMD-AR 方法;即使在信噪比降低和非平稳性增大的情况下,VMD-AR 方法仍然具有较好的锁相性能。该方法通过 VMD 方法降低了 EEG 的非平稳性,有效提高了 AR 模型的预测精度,从而达到提高系统锁相性能的目的。研究结果可以扩大锁相刺激技术在神经振荡调节领域的应用范围,对于未来开发闭环锁相神经刺激仪器具有一定的参考价值。

然而,VMD 方法是一种基于频域的分解技术,与 EMD 等时域分解方法相比,存在计算耗时长不足。若要应用于实时系统中,需进一步解决算法时间开销问题。此外,中心模态个数会影响 VMD 方法的分解效果和计算时长,如何合理地确定中心模态个数还缺乏有效的方法。

参考文献

- [1] MANSOURI F, SHANBOUR A, MAZZA F, et al. Effect of theta transcranial alternating current stimulation and phase-locked transcranial pulsed current stimulation on learning and cognitive control [J]. *Frontiers in Neuroscience*, 2019, 13:1181.
- [2] KASTEN F H, HERRMANN C S. Recovering brain dynamics during concurrent tACS/EEG: An overview of analysis approaches and their methodological and interpretational pitfalls[J]. *Brain Topography*, 2019, 32: 1013-1019.
- [3] D'ANDOLA M, GIULIONI M, DANTE V, et al. Control of cortical oscillatory frequency by a closed-loop system[J]. *Journal of Neuro Engineering and Rehabilitation*, 2019, 16:7.
- [4] KRAUSEA M R, VIEIRAA P G, CAORBAA B A, et al. Transcranial alternating current stimulation entrains single-neuron activity in the primate brain[J]. *PNAS*, 2019,116(12): 5747-5755.
- [5] NUNEZ M, ZINBARG R E, MITTAL V A. Efficacy and mechanisms of non-invasive brain stimulation to enhance exposure therapy: A review [J]. *Clinical Psychology Review*, 2019, 70: 64-78.
- [6] KASTEN F H, MAESS B, HERRMANN C S. Facilitated

event-related power modulations during transcranial alternating current stimulation (tACS) revealed by concurrent tACS-MEG[J]. *eNeuro*, 2018, 5(3) e0069.

- [7] HUANG G, LIU J, LI L L, et al. A novel training-free externally-regulated neurofeedback (ER-NF) system using phase-guided visual stimulation for alpha modulation[J]. *NeuroImage*, 2019, 189:688-699.
- [8] HYMAN J M, WYBLE B P, GOYAL V, et al. Stimulation in hippocampal region CA1 in behaving rats yields long-term potentiation when delivered to the peak of theta and long-term depression when delivered to the trough[J]. *The Journal of Neuroscience*, 2003, 23 (37): 11725-11731.
- [9] 封洲燕,陈丹,肖乾江.一种闭环式神经电刺激系统的设计[J]. *仪器仪表学报*, 2012, 33(2):279-285.
FENG ZH Y, CHEN D, XIAO Q J. Design of a novel closed-loop neural electrical stimulation system [J]. *Chinese Journal of Scientific Instrument*, 2012, 33(2): 279-285.
- [10] MANSOURI F, FETTES P, SCHULZE L, et al. A real-time phase-locking system for non-invasive brain stimulation[J]. *Frontiers in Neuroscience*, 2018, 12: 877.
- [11] CHUNG S W, SULLIVAN C M, ROGASCH N C, et al. The effects of individualised intermittent theta burst stimulation in the prefrontal cortex: A TMS-EEG study[J]. *Human Brain Mapping*, 2018, 40 (2): 608-627.
- [12] ZARUBIN G, GUNDLACH C, NIKULIN V, et al. Real-time phase detection for EEG-based tACS closed-loop system [C]. In *Proceedings of the 6th International Congress on Neurotechnology, Electronics and Informatics*, 2018:13-20.
- [13] CHEN L L, MADHAVAN R, RAPOPORT B I, et al. Real-time brain oscillation detection and phase-locked stimulation using autoregressive spectral estimation and time-series forward prediction[J]. *IEEE Transactions on Biomedical Engineering*, 2013, 60(3):753-762.
- [14] MANSOURI F, DUNLOP K, GIACOBBE P, et al. A fast EEG forecasting algorithm for phase-locked transcranial electrical stimulation of the human brain[J]. *Frontiers in Neuroscience*, 2017, 11:401.
- [15] 张鹏博,王雪,张蔚航,等.癫痫发作瞬态带宽特征自适应检测方法 [J]. *仪器仪表学报*, 2016, 37 (6): 1390-1397.
ZHANG P B, WANG X, ZHANG W H, et al. Adaptive detection method based on instantaneous bandwidth feature for seizure onset[J]. *Chinese Journal of Scientific*

- Instrument, 2016, 37(6):1390-1397.
- [16] 杨默涵,陈万忠,李明阳. 基于总体经验模态分解的多类特征的运动想象脑电识别方法研究. 自动化学报, 2017, 43(5): 743-752.
YANG M H, CHEN W ZH, LI M Y. Multiple feature extraction based on ensemble empirical mode decomposition for motor imagery EEG recognition tasks[J]. Acta Automatica Sinica, 2017, 43(5): 743-752.
- [17] 刘景良,郑锦仰,林友勤,等. 变分模态分解和同步挤压小波变换识别时变结构瞬时频率[J]. 振动与冲击, 2018, 37(20):24-31.
LIU J L, ZHENG J Y, LIN Y Q, et al. Instantaneous frequency identification of time-varying structures using variational mode decomposition and synchrosqueezing wavelet transform[J]. Journal of Vibration and Shock, 2018, 37(20):24-31.
- [18] 张淑清,宿新爽,陈荣飞,等. 基于变分模态分解和FABP的短期电力负荷预测[J]. 仪器仪表学报, 2018, 39(4):67-73.
ZHANG SH Q, SU X SH, CHEN R F, et al. Short-term load forecasting based on the VMD and FABP [J]. Chinese Journal of Scientific Instrument, 2018, 39(4): 67-73.
- [19] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3):531-544.

- [20] BENWELL C S Y, LONDON R E, TAGLIABUE C F, et al. Frequency and power of human alpha oscillations drift systematically with time-on-task[J]. NeuroImage, 2019, 192:101-114.

作者简介



陈妮,2004年和2010年于广西大学分别获得学士学位和硕士学位,现为广西大学博士研究生、广西医科大学讲师,主要研究方向为脑机接口、无创脑刺激。

E-mail: lizi0908@163.com

Chen Ni received her B. Sc. degree and M. Sc. degree both from Guangxi University in 2004 and 2010. She is currently a Ph. D. candidate at Guangxi University and a lecturer at Guangxi Medical University. Her main research interests include brain-computer interface and non-invasive brain stimulation.



覃玉荣(通信作者),2005年于华南理工大学获得博士学位,现为广西大学教授、博士生导师,主要研究方向为脑认知、脑机接口等。

E-mail: qyr111@163.com

Qin Yurong (Corresponding author) received her Ph. D. degree from South China University of Technology in 2005. She is currently a professor at Guangxi University. Her main research interests include brain cognition, brain-computer interface, etc.