·医学工程·

基于辛稀疏模态分解的抑郁症患者脑电信号眼电伪迹自适应去除方法研究

张伟[1a] 涂伟[1b*] 邓国金[2] 戴进军[1c]

（1. 湖南省第二人民医院 a. 神志病中医药诊疗中心；b. 神经外科三病区；c. 护理部，长沙 410007；
2. 长沙市望城区精神病医院精神一科，长沙 410007）

【摘要】 抑郁症患者脑电信号反映了大脑内部神经元的放电活动，含有丰富的病理信息。然而，脑电微弱信号在采集中易受眨眼等生理行为造成的眼电噪声干扰。针对传统自适应信号分解方法应用于抑郁症患者脑电信号眼电伪迹去除时物理意义不足且缺乏鲁棒性的问题，提出了辛稀疏模态分解（symplectic sparsest mode decomposition, SSMD）方法。该方法首先构建辛几何原子库，并采用能量阈值评估各初始单分量的有效性。然后采用自适应滤波器对辛几何原子进行初始化自适应降噪，从而提升原子质量及算法的鲁棒性。最后以局部窄带算子为优化目标，从而使得分解结果具有更好的物理意义。仿真和实验分析结果表明，相较辛几何模态分解（symplectic geometry mode decomposition, SGMD）、变分模态分解（variational mode decomposition, VMD）和互补集合经验模态分解（complementary ensemble empirical mode decomposition, CEEMD）方法，SSMD 能更准确地将抑郁症患者的有效 EEG 信息和眼电伪迹分离开来。抑郁症患者 EEG 信号采用 SSMD 方法降噪后的复合多尺度模糊熵（composite multi-scale fuzzy entropy, CMFE）四分位差仅为 0.14，相对其他方法而言，其数据离散程度更低、聚集性更强、信号突变干扰更少。

【关键词】 脑电信号；眼电伪迹；辛稀疏模态分解；局部窄带算子；辛几何模态分量；抑郁

【中图分类号】 TN911.7 **【文献标识码】** A **【DOI】** 10.11876/mimt202602003

Research on an adaptive removal method for electrooculogram artifacts in electroencephalogram signals of depression patients based on symplectic sparse mode decomposition

Zhang Wei[1a], Tu Wei[1b], Deng Guojin[2], Dai Jinjun[1c]*

(*1. a. Traditional Chinese Medicine Diagnosis and Treatment Center for Mental Disorders; b. Department 3 of Neurosurgery; c. Nursing Department, the Second People's Hospital of Hunan Province, Changsha 410007, China; 2. Department of Psychiatry I, Wangcheng District Psychiatric Hospital, Changsha 410007, China*)

【Abstract】 The electroencephalogram (EEG) signals of patients with depression reflect the discharge activities of neurons within the brain and contain abundant pathological information. However, the weak EEG signals are prone to be interfered by eye-electrical noise caused by physiological behaviors such as blinking during acquisition. To address the problem that the traditional adaptive signal decomposition methods have insufficient physical meaning and lack robustness when applied to the removal of electrooculography artifacts from the EEG signals of patients with depression, the symplectic sparsest mode decomposition (SSMD) method is proposed. This method first constructs a symplectic geometric atom library and evaluates the effectiveness of each initial single component using an energy threshold. Then, an adaptive filter is used to initialize the adaptive denoising of the symplectic

基金项目：湖南省自然科学基金项目（2024JJ9356）

第一作者：张伟，男，本科，主管护师，研究方向：无创脑刺激，脑电认知识别等

通信作者：涂伟，女，本科，主管护师，研究方向：抑郁等精神疾病护理

geometric atoms, thereby improving the atom quality and the robustness of the algorithm. Finally, with the local narrowband operator as the optimization objective, the decomposition results have better physical meaning. Simulation and experimental analysis results show that compared with the symplectic geometry mode decomposition (SGMD), variational mode decomposition (VMD), and complementary ensemble empirical mode decomposition (CEEMD) methods, SSMD can more accurately separate the effective EEG information and electrooculography artifacts of patients with depression. The quartile difference of the composite multi-scale fuzzy entropy (CMFE) of the EEG signals of patients with depression after noise reduction using the SSMD method is only 0.14, which has a lower data dispersion, stronger aggregation, and less signal mutation interference compared to other methods.

【Key words】 Electroencephalogram signal; Electrooculography artifacts; Symplectic sparsest mode decomposition; Local narrowband operator; Symplectic geometric mode components; Depression

抑郁症是一种以持久而反复的伤感、内疚感和无用感为主要特征的精神疾病。以往基于神经影像学对抑郁症患者脑网络的研究结果虽然并不完全一致，但可以证实其脑网络的随机化有很强的收敛趋势[1]。脑电（electroencephalogram, EEG）信号是大量的神经活动在头皮处的总体反映，蕴含着丰富的生理和病理信息，具备非侵入性、高时间分辨率等优势，已作为神经精神疾病的检测工具在临床广泛应用[2]。EEG信号幅值在100 μV以下，采集过程极易受到噪声干扰，产生信号伪迹。其中，眼电伪迹幅值较大，易致EEG信号产生畸变，且眼电伪迹占据与神经性活动EEG信号相重叠的频带，通过简单的滤波去噪方法难以有效消除[3]。因此，如何有效地去除眼电伪迹以获得包含抑郁症特征信息的分析数据，是EEG信号处理领域的重要课题[4]。

目前，信号自适应分解方法已经广泛应用于脑电伪迹去除领域[5-12]。经验模态分解（empirical mode decomposition, EMD）及其衍生算法如互补集合经验模态分解（complementary ensemble empirical mode decomposition, CEEMD）、多元集合经验模态分解（multivariate ensemble empirical mode decomposition, MEEMD）和变分模态分解（variational mode decomposition, VMD）等已被应用在脑电伪迹去除领域并对于眼电伪迹存在的频带混淆问题有较好的效果[5-8]。匹配追踪（matching pursuit, MP）和组稀疏信号去噪（group-sparse signal denoising, GSSD）等算法通过稀疏分解将信号分解成多个低维、不相关的成分，将其中视为伪迹的成分去除从而实现EEG信号去噪[9-11]。然而，传统自适应信号分解方法当信号被强噪声干扰时或存在复杂耦合的频率成分时，难以准确分离不同的模态信息，同时，算法分解得到的分量是否具有物理意义也缺少相应的数学证明[12-13]。

辛几何模态分解（symplectic geometry mode decomposition, SGMD）方法无需预先设置参数，且能通过辛相似变换保护数据结构，从而有效去除噪声，且具有较好的模态混叠能力，然而SGMD仍然存在分解结果缺乏物理意义和鲁棒性不足的问题[14-15]。因此，本研究采用辛稀疏模态分解（symplectic sparsest mode decomposition, SSMD）方法去除抑郁症患者EEG信号中的眼电伪迹。首先构建原始EEG信号的辛几何原子库，并采用能量阈值评估各初始单分量的有效性，通过约束原子个数有效提升分解速度。然后针对辛几何原子可能存在的模态混淆和端点效应等问题，采用自适应滤波器对辛几何原子进行初始化自适应降噪，从而提升原子质量及算法的鲁棒性。最后以正则化局部窄带算子为优化目标，从而使得分解结果具有更好的物理意义。通过实验数据分析表明，该方法能有效提升SGMD方法的分解效率，且能更为准确地去除抑郁症患者EEG信号中的眼电伪迹。

1 辛稀疏模态分解方法

1.1 奇异局部线性算子

若 $\forall t \in \mathrm{R}$，对于 t 的邻域 B_t 存在：

$$T(s)(t) = T(s|_{B_t})(t), (\forall s \in L^2(\mathrm{R})) \quad (1)$$

其中，若函数 s 在邻域 B_t 上受限，则定义为 $s|_{B_t}$。若 T 表现出奇异性，则该算子是奇异局部算子。设 B_t 是根据奇异局部线性算子定义的邻域。

针对窄带EEG信号 $(at+b)\cos(\omega t+c)$，微分算子

可定义如下：

$$T=\left(\frac{1}{\omega^2}\frac{\mathrm{d}^2}{\mathrm{d}t^2}+1\right)^2 \tag{2}$$

那么在 t 的任意邻域均存在：

$$\left(\frac{1}{\omega^2}\frac{\mathrm{d}^2}{\mathrm{d}t^2}+1\right)^2(at+b)\cos(\omega t+c)=0 \tag{3}$$

窄带信号 $(at+b)\cos(\omega t+c)$ 在微分算子 T 的作用下计算结果为 0，因此，要让 s 处于算子 T 的窄带空间，那么就要令 $\|T(s)\|_2^2$ 最小。

1.2 辛稀疏模态分解方法流程

SSMD 方法分为辛几何原子库构建、原子自适应降噪和辛稀疏模态分量（symplectic sparsest mode component, SSMC）重构 3 个主要步骤。首先，基于辛几何模态分解的初始分量构建辛几何原子库，并通过能量阈值评估各初始单分量的有效性，约束原子个数，从而有效提升分解速度。其次，构建稀疏滤波器，对辛几何原子进行初始化自适应降噪，从而提升原子质量及算法的鲁棒性，缓解辛几何原子可能存在的模态混淆和端点效应等问题。最后，以正则化局部窄带算子为优化目标对辛几何原子进行优化重构，使约束为局部窄带信号的分解结果具备更好的物理意义。

1.2.1 步骤 1：辛几何原子库构建

（1）令 $r_1(t)=x(t)$，其中，$x(t)$ 为原始 EEG 信号，$r_1(t)$ 为每次迭代的残余量。

（2）获取初始单分量矩阵 $\boldsymbol{Z}$，采用对角平均化对初始单分量矩阵 $\boldsymbol{Z}$ 进行转换，获取辛几何原子 y_k。

（3）计算每个辛几何原子 $y_k(t)$ 与原始信号 $r_1(t)$ 的能量比 E_r，当能量比小于阈值 ε 时终止生成新的辛几何原子，通常可设置为 0.001。然后，根据辛几何原子能量 $\|y_k(t)\|_2^2$ 大小对辛几何原子有效性进行排序，构建原始信号 $x(t)$ 的辛几何原子库。

$$E_\mathrm{r}=\frac{\|y_k(t)\|_2^2}{\|r_1(t)\|_2^2} \tag{4}$$

此步骤无需获取整体初始单分量矩阵，可通过约束原子个数从而有效提升分解速度，并可有效降低无效辛几何原子对分解精度的不利影响。

1.2.2 步骤 2：辛几何原子自适应降噪

（1）建立滤波器 $\chi(k\mid\lambda)$，如式（5）所示，其中 k 为滤波器频域横坐标，λ 为滤波器参数向量，$\lambda=[\omega,\omega_b,\omega_c]$，其中 ω、ω_b 和 ω_c 分别为滤波器衰减速率、带宽和中心频率。

$$\chi(k\mid\lambda)=\begin{cases}\sin\omega\left[\dfrac{k-\omega_c+\omega_b+\pi}{2\omega}\right], & \dfrac{\omega_c-\omega_b-\pi}{2\omega}\leqslant k<\omega_c-\omega_b\\ 1, & \omega_c-\omega_b\leqslant k\leqslant\omega_c+\omega_b\\ \cos\omega(k-\omega_c-\omega_b), & \omega_c+\omega_b<k\leqslant\dfrac{\omega_c+\omega_b+\pi}{2\omega}\\ 0, & \text{其他}\end{cases} \tag{5}$$

解决如下优化问题 P1，通过遗传算法获取辛几何原子 $y_k(t)$ 的最优滤波参数 $\lambda=[\omega,\omega_b,\omega_c]$。

$$\text{P1：Minimize }\left\|\mathrm{D}[\hat{y}_k(t)]\right\|_2^2+\beta\left\|\mathrm{D}[y_k(t)-\hat{y}_k(t)]\right\|_2^2 \tag{6}$$

其中，$\hat{y}_k(t)=ifft[\chi(k\mid\lambda_0)fft[y_k(t)]]$ 为降噪后的辛几何原子，D 是微分算子，*fft* 和 *ifft* 分别代表傅里叶变换和傅里叶逆变换，β 为算子权值。

该优化问题通过最小化 $\|\mathrm{D}[\hat{y}_k(t)]\|_2^2$ 使得降噪后的 $y_k(t)$ 更平滑，从而达到自适应降噪的目的。$\beta\|\mathrm{D}[y_k(t)-\hat{y}_k(t)]\|_2^2$ 用于正则化优化目标函数，其中权值 β 通常可设置为 1。

（2）所有原子降噪后构建新的辛几何原子库 $\hat{Y}$：

$$\hat{Y}=[\hat{y}_1,\hat{y}_2,\cdots,\hat{y}_k,\cdots,\hat{y}_n] \tag{7}$$

此步骤将自适应降噪问题转换为滤波器参数的寻优过程，可有效缓解辛几何原子存在的模态混淆和端点效应等问题，从而提升原子质量及算法鲁棒性。

1.2.3 步骤 3：辛几何模态分量重构

（1）令 $res_1(t)=x(t)$，$res_1(t)$ 为残余量值。

（2）解决如下优化问题 P2。

$$\text{P2：Minimize }\left\|T\left[SSMC_i(t)\right]\right\|_2^2+\eta\left\|\mathrm{D}\left[res_i(t)-SSMC_i(t)\right]\right\|^2 \tag{8}$$

在优化问题 P2 中，优化参数为各辛几何原子的序号，$\|T[SSMC_i(t)]\|_2^2$ 为采用公式（2）所示算子对辛几何原子合并后获取的 SSMC 分量，算子 T 的使用是为了将分解得到的分量约束为局部窄带信号。

与优化问题 P1 类似，$\eta\|\mathrm{D}[res_i(t)-SSMC_i(t)]\|^2$ 用于正则化优化目标函数，以获取原始信号的最稀疏表示，其权值 η 通常设置为 1。获取待合并的最优辛几何原子序号后，根据序号可构建 $SSMC_i(t)$，同时将已合并的辛几何原子从原子库中去除。

（3）解决如下优化问题 P3，参数为幅值系数 μ。

$$\text{P3：Minimize }\left\|res_i(t)-\mu SSMC_i(t)\right\|^2 \tag{9}$$

本步骤的目的是获取 $SSMC_i(t)$ 的最优幅值，进一步确保分解结果的稀疏性。

（4）若辛几何原子库已清空则终止迭代，若未清空，则计算迭代终止条件 $\frac{\|SSMC_i(t)\|_2^2}{\|x(t)\|_2^2} \leqslant \varepsilon$，若满足条件则终止迭代，否则返回步骤2。

为获得具有更好物理意义的分解结果，SSMD将辛几何模态分量约束为窄带信号。同时，因其拥有保持信号本质结构与时间序列内在特征不变的优点，SSMD引入辛几何相似变换来构建过完备字典库，从而有效提升原子质量及算法鲁棒性。

2 实验数据分析验证

2.1 数据来源及预处理

本研究所采用的静息态EEG数据来源于甘肃省可穿戴装备重点实验室公开数据集[16]。依据该数据集原始研究方案，所有受试者在数据采集前均已充分知晓研究内容、实验流程、检测用途及潜在风险，自愿参与本次研究并签署书面知情同意书。本研究的实验设计、数据采集方案及受试者招募流程均经由兰州大学第二医院生物医学研究伦理委员会审核批准，全程严格恪守《赫尔辛基宣言》核心伦理准则，所有数据采集、存储及后续分析使用流程均符合人体生物医学研究相关规范。

该数据集受试者被分为抑郁症患者组与健康对照组，所有受试者均为汉族，年龄18～55周岁。其中抑郁症患者组均为临床确诊的抑郁障碍患者，健康对照组受试者无精神类疾病病史，两组受试者在年龄、性别、受教育年限等基础人口学资料上差异无统计学意义，基线水平均衡可比，可有效排除基础个体差异对实验结果的干扰。纳入标准和排除标准如下。

（1）纳入标准

抑郁症患者组：①符合《精神障碍诊断与统计手册（第五版）》（DSM-5）抑郁障碍诊断标准；②年龄处于18～55周岁；③意识清晰，能够配合完成全程脑电采集实验；④自愿参与研究并签署知情同意书。健康对照组：①无抑郁、焦虑、精神分裂等各类精神疾病史；②无家族遗传性精神疾病病史；③近期无重大应激事件及情绪异常状态；④身体各项基础指标正常，可配合完成实验采集。

（2）排除标准

①存在颅脑外伤、脑部器质性病变、癫痫等神经系统疾病；②存在严重心、肝、肾等躯体重大疾病；③有酒精、药物依赖史；④存在认知功能障碍，无法配合实验操作；⑤近期服用精神类、镇静类影响EEG信号的药物；⑥妊娠期、哺乳期人群。

该数据集受试者EEG数据采集于2018年3月至2019年10月期间，所有受试者检测均避开作息紊乱、身体不适、情绪剧烈波动等特殊时段，统一选择日间平稳时段开展数据采集，保证采集环境与受试者状态的统一性。采集地点位于甘肃省可穿戴装备重点实验室，实验室配备专业屏蔽设备，可有效隔绝电磁、噪音等外界环境干扰，满足EEG微弱电信号的高精度采集条件，保障原始数据的有效性与可靠性。采集设备由美国Electrical Geodesics Inc公司生产的HydroCel Geodesic Sensor Net（HCGSN）128导脑电帽、Net Amps 200脑电放大器以及Net Station 5.4软件组成。设置采样率为250 Hz，在测量过程中保证每个电极的阻抗在50 kΩ以下，研究人员通过E-prime程序控制实验过程，待观测到受试者的EEG信号趋于平稳时，则开始进行EEG信号的连续采集，获取的抑郁症患者和健康对照者的EEG信号如图1所示。受试者包括24名抑郁症患者和29名健康对照者，每组测试时长为5 min，单通道每次获取的数据点数为75 000个左右，原始数据集未对采集的128个电极通道数据进行预处理。

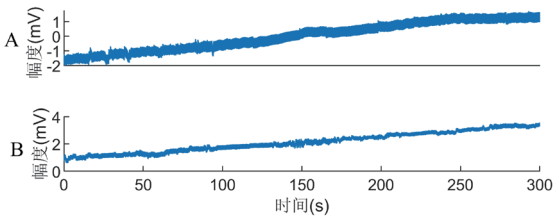


图1 采集的原始EEG信号 A为抑郁症患者EEG信号；B为健康对照者EEG信号

注：EEG为脑电。

由于人脑包含有效信息的频段通常受到工频干扰并且＞0.5 Hz[2]，因此采用有限脉冲响应（finite impulse response, FIR）带通滤波器对原始信号进行预处理，去除50 Hz工频并滤除0.5 Hz以下频率，获取的滤波后EEG信号如图2所示。

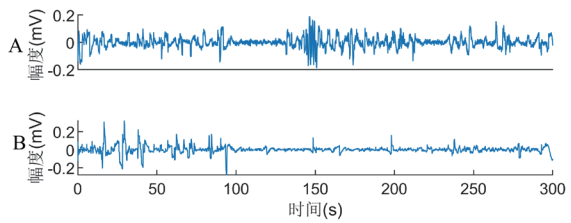


图 2 滤波后的 EEG 信号 A 为抑郁症患者滤波后 EEG 信号；B 为健康对照者滤波后 EEG 信号

注：EEG 为脑电。

2.2 本研究 SSMD 算法与 SGMD、VMD 和 CEEMD 算法的对比分析

为验证本研究算法的可靠性，针对图 2 中抑郁症患者和健康对照者预处理后的 EEG 信号进行分析，将采用传统 CEEMD 和 VMD 算法以及 SGMD 方法的分析结果与本研究 SSMD 算法的分析结果进行对比。健康对照者 EEG 信号降噪结果和 EEG 眼电伪迹信号见图 3 和图 4，抑郁症患者 EEG 信号降噪结果和 EEG 眼电伪迹信号见图 5 和图 6。由于抑郁症患者和健康对照者在排除眼电伪迹后的纯净 EEG 信号上均表现出显著的周期性和调幅调频特性，而典型伪迹信号通常表现为非周期性的冲击波形。因此，从图 3A 和图 5A 中可以看出，SSMD 降噪后的 EEG 信号还原出了较好的周期性，信号波动较小；而图 4A 和图 6A 中的非周期性冲击则多为眼电伪迹所引起。从图 3B 和图 5B 中可以看出，SGMD 降噪后的 EEG 信号虽然具有较好的周期性，但仍包含部分微弱冲击波形；图 4B 和图 6B 中分离得到的眼电伪迹信号也出现了部分虚假伪迹冲击。从图 3C 和图 5C 中可以看出，VMD 在一定程度上可以有效分离伪迹信息，然而从图 3C 可见，健康对照者降噪后的 EEG 信号中仍出现了明显的冲击，这是由 VMD 分解过程中的模态混淆所导致的。从图 3D 中可以看出，CEEMD 降噪后的健康对照者 EEG 信号出现了较为严重的模态混淆，导致眼电伪迹冲击模态和有效 EEG 信息相互混叠。因此，相对 SGMD、VMD 和 CEEMD 而言，SSMD 能更准确地将抑郁症患者的有效 EEG 信息和眼电伪迹分离开来。此外，SSMD、SGMD、VMD 和 CEEMD 方法的计算时间分别是 7.53 s、45.36 s、4.28 s 和 2.24 s。可以看出，由于采用的优化算法在提升计算精度的同时增加了计算复杂度，SSMD 方法的计算效率相对 VMD 和 CEEMD 算法较低。但是相较 SGMD 方法，SSMD 方法的计算速度仍有大幅提升，这是由于 SSMD 通过约束原子个数有效提升了分解速度，从而节省了原算法中的大量无效计算。

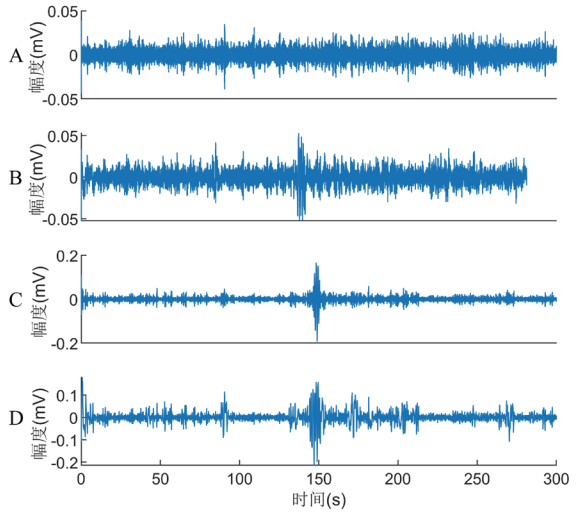


图 3 健康对照者 EEG 信号降噪结果 A 为 SSMD 算法；B 为 SGMD 算法；C 为 VMD 算法；D 为 CEEMD 算法

注：EEG 为脑电；SSMD 为辛稀疏模态分解；SGMD 为辛几何模态分解；VMD 为变分模态分解；CEEMD 为互补集合经验模态分解。

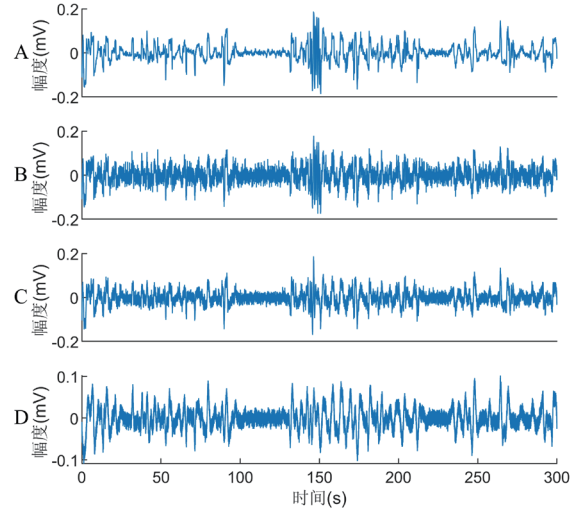


图 4 健康对照者 EEG 信号中的眼电伪迹信号 A 为 SSMD 算法；B 为 SGMD 算法；C 为 VMD 算法；D 为 CEEMD 算法

注：EEG 为脑电；SSMD 为辛稀疏模态分解；SGMD 为辛几何模态分解；VMD 为变分模态分解；CEEMD 为互补集合经验模态分解。

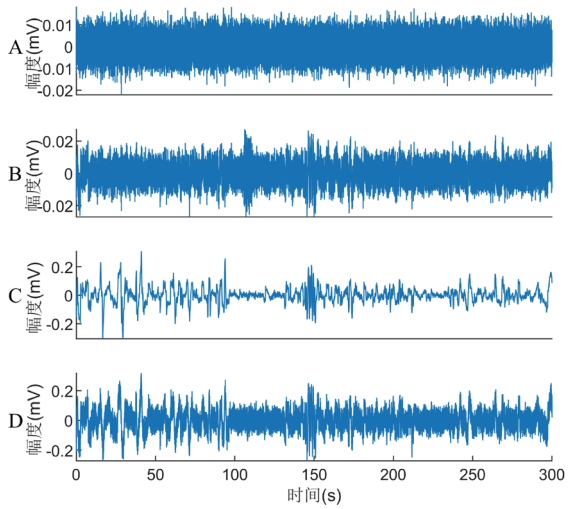


图5 抑郁症患者EEG信号降噪结果 A为SSMD算法；B为SGMD算法；C为VMD算法；D为CEEMD算法

注：EEG为脑电；SSMD为辛稀疏模态分解；SGMD为辛几何模态分解；VMD为变分模态分解；CEEMD为互补集合经验模态分解。

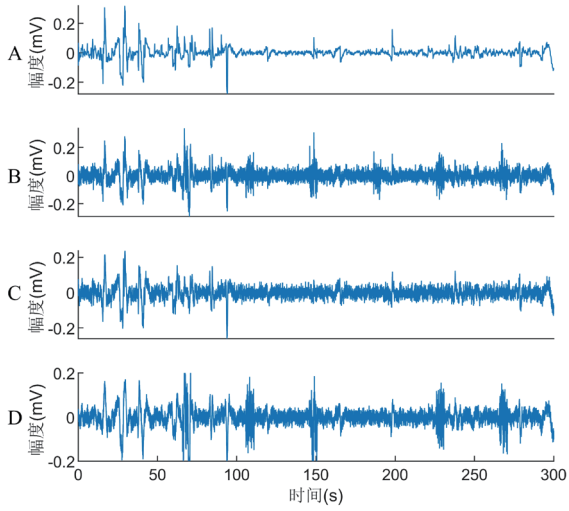


图6 抑郁症患者EEG信号中的眼电伪迹信号 A为SSMD算法；B为SGMD算法；C为VMD算法；D为CEEMD算法

注：EEG为脑电；SSMD为辛稀疏模态分解；SGMD为辛几何模态分解；VMD为变分模态分解；CEEMD为互补集合经验模态分解。

复合多尺度模糊熵（composite multi-scale fuzzy entropy, CMFE）[17]能有效表征不同尺度上信号的复杂程度，抑郁症患者反刍思维高、情绪易失调、认知状态过度活跃，导致其EEG信号复杂程度上升，因此，其EEG信号的CMFE值高于健康人群。为进一步验证SSMD相对于传统算法的优势，采用CMFE对分析结果的复杂度进行量化表征。随机抽取20名抑郁症患者和20名健康对照者的EEG数据作为样本库，为进行有效对比，所有被试者EEG数据均采用电极通道E1的数据。将每名被试者5 min的测试数据分成5份，每个样本包含1 min的EEG数据，因此，抑郁症患者和健康对照者分别提取100个数据样本，从而确保所构建的样本库尽量覆盖不同测试人群和测试过程中被试者的不同状态。不同算法分析结果的CMFE箱型图如图7至图10所示，可以看出，相对SGMD、VMD和CEEMD，SSMD分析结果的CMFE值离散程度更低，且突变程度更小，表明SSMD方法能更有效地提取抑郁症患者的EEG信息并通过CMFE进行准确表征。

为进一步验证SSMD方法对抑郁症患者EEG信号进行降噪的有效性，表1中列出了CMFE的中位数和四分位差2个量化指标。CMFE是表征非线性时间序列复杂程度的有效量化方法，可通过计算不同尺度下信号序列的模糊相似度，客观反映EEG信号的混沌特性与细微波动特征，能够有效挖掘脑部电活动的隐匿差异。中位数为各组样本CMFE数值的中间值，可规避极端异常值干扰，客观反映各组样本CMFE特征的整体平均水平；四分位差为上四分位数与下四分位数的差值，主要用于衡量样本数据的离散、波动程度，数值越小说明数据分布越集中、稳定性越好。

通过表1量化结果分析可知，在组间差异层面，抑郁症患者组的CMFE中位数显著高于健康对照组，表明抑郁症患者的EEG信号复杂度整体异于健康人群，也证明CMFE特征可有效表征抑郁症患者EEG信号的异常复杂度特征，可作为区分抑郁症病理EEG与正常EEG的有效指标。在降噪方法性能对比层面，经SSMD方法降噪处理后的EEG信号CMFE四分位差相较于其他降噪方法显著更小，说明SSMD方法处理后的EEG数据离散程度更低、数值聚集性更强，降噪后EEG信号的特征数据稳定性更优。

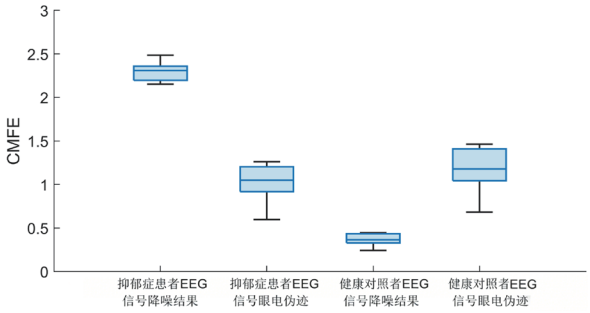


图 7 EEG 信号 SSMD 分析结果的 CMFE 箱型图

注：EEG 为脑电；SSMD 为辛稀疏模态分解；CMFE 为复合多尺度模糊熵。

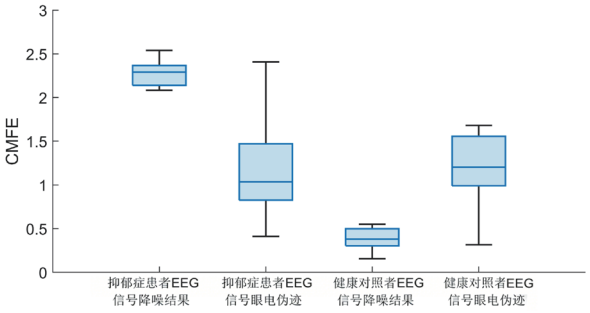


图 9 EEG 信号 VMD 分析结果的 CMFE 箱型图

注：EEG 为脑电；VMD 为变分模态分解；CMFE 为复合多尺度模糊熵。

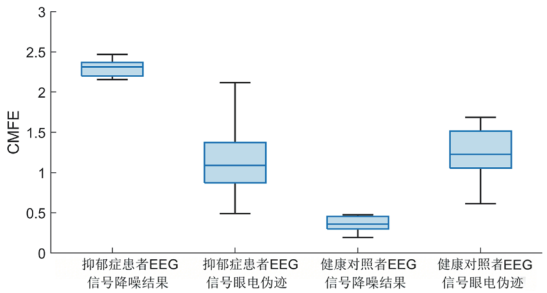


图 8 EEG 信号 SGMD 分析结果的 CMFE 箱型图

注：EEG 为脑电；SGMD 为辛几何模态分解；CMFE 为复合多尺度模糊熵。

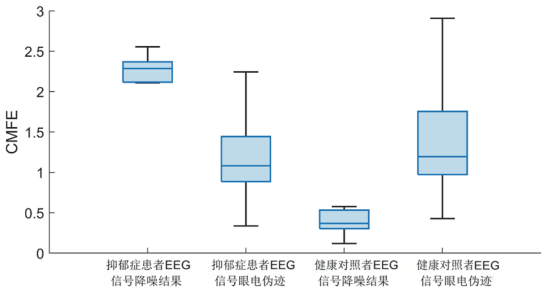


图 10 EEG 信号 CEEMD 分析结果的 CMFE 箱型图

注：EEG 为脑电；CEEMD 为互补集合经验模态分解；CMFE 为复合多尺度模糊熵。

表 1 CMFE 箱型图量化指标

分析方法	抑郁症患者 EEG 信号降噪结果		抑郁症患者 EEG 信号眼电伪迹		健康对照者 EEG 信号降噪结果		健康对照者 EEG 信号眼电伪迹	
	中位数	四分位差	中位数	四分位差	中位数	四分位差	中位数	四分位差
SSMD	2.30	0.14	1.03	0.33	0.35	0.11	1.19	0.34
SGMD	2.32	0.17	1.09	0.51	0.30	0.16	1.23	0.46
VMD	2.29	0.25	1.09	0.58	0.40	0.19	1.15	0.84
CEEMD	2.35	0.22	1.01	0.50	0.37	0.18	1.26	0.75

注：CMFE 为复合多尺度模糊熵；SSMD 为辛稀疏模态分解；SGMD 为辛几何模态分解；VMD 为变分模态分解；CEEMD 为互补集合经验模态分解；EEG 为脑电。

3 讨论

EEG 信号是解析大脑神经活动、诊断和评估精神类疾病的核心生理信号，具备高时间分辨率、无创、便捷的优势，被广泛应用于抑郁症的病理机制研究与辅助诊断领域。但在实际采集过程中，眼电伪迹是干扰 EEG 信号的主要噪声来源，会掩盖真实的 EEG 活动特征，导致信号分析结果失真，从而影响抑郁症 EEG 特征识别的准确性。因此，本研究提出了用于抑郁症患者 EEG 信号自适应降噪的 SSMD 方法，以实现眼电伪迹和有效信息的准确分离，具体如下。

（1）针对传统自适应信号分解方法处理抑郁症 EEG 信号存在物理意义模糊、鲁棒性较差的问题，本研究提出 SSMD 方法，用于抑郁症 EEG 信号眼电伪迹的自适应去除。该方法依托辛几何理论构建原子库，结合能量阈值筛选有效信号分量，通过自适应滤波器优化原子降噪质量，提升算法抗干扰能力与鲁棒性；同时引入局部窄带算子约束分解过程，使分解结果贴合 EEG 生理特征，有效解决了传统算法物理意义不明确的缺陷，为病理 EEG 精细化预处理提供了新型处理方法。

（2）本研究采用 CMFE 的中位数及四分位差作

为量化指标，对比SSMD与SGMD、VMD、CEEMD方法的降噪效果。实验结果表明，SSMD降噪后EEG信号的CMFE四分位差仅为0.14，相较于传统方法，数据离散度更低、聚集性更强、信号突变干扰更少。该方法可在完整保留抑郁症EEG病理有效信息的前提下，精准去除眼电伪迹，有效避免了EEG信号特征失真问题，充分验证了SSMD在抑郁症EEG预处理中的优越性与有效性。

（3）本研究提出的SSMD方法弥补了传统算法的技术短板，可为抑郁症EEG机制研究与辅助诊断提供技术支撑，其自适应伪迹分离思路亦可推广至各类生物电信号处理，具备良好的科研与工程应用价值。然而本研究仍存在一定局限性，如仅针对静息态EEG的眼电伪迹开展实验，未考虑药物、情绪等混杂因素，且未验证算法对混合伪迹的处理能力，性能评估指标维度较为单一。后续可扩充多场景临床数据集，优化算法结构，结合多维度EEG特征构建智能诊断模型，推动算法临床应用。

[参 考 文 献]

[1] 任书瑶, 宋江玲, 张瑞. 一种基于EEG信号的抑郁症早期筛查方法[J]. 计算机科学, 2023, 50(S2): 1011–1016.

[2] 荆舒, 戴振威, 苏小游. 脑电信号在抑郁和焦虑障碍识别中的应用[J]. 中华行为医学与脑科学杂志, 2025, 34(1): 89–94.

[3] 李易霖, 周彪. 基于通道筛选和自适应熵阈值的眼电伪迹自动去除算法[J]. 计算机工程与科学, 2024, 46(12): 2271–2280.

[4] 徐雨, 郑威, 程怡. 基于单通道脑电信号中眼电伪迹去除的方法[J]. 生物医学工程研究, 2022, 41(4): 369–375, 416.

[5] Patel R, Gireesan K, Baskaran R. Combining CEEMDAN with PCA for effective cardiac artefact suppression from single–channel EEG[J]. Journal of Scientific and Industrial Research, 2022, 81(11): 5.

[6] Wu Q, Zhang W Q, Wang Y, et al. Research on removal algorithm of EOG artifacts in single–channel EEG signals based on CEEMDAN–BD[J]. Computer Methods in Biomechanics and Biomedical Engineering, 2021, 24(12): 1368–1379..

[7] Saini M, Payal, Satija U. An effective and robust framework for ocular artifact removal from single–channel EEG signal based on variational mode decomposition[J]. IEEE Sensors Journal, 2020, 20(1): 369–376.

[8] 张学军, 景鹏, 何涛, 等. 基于变分模态分解的癫痫脑电信号分类方法[J]. 电子学报, 2020, 48(12): 2469–2475.

[9] Wang Q, Kong W, Zhong J. et al. A hybrid SVM and kernel function–based sparse representation classification for automated epilepsy detection in EEG signals[J]. Neurocomputing, 2023, 562: 126874.

[10] Qu M, Chang C, Wang J, et al. Nonnegative block–sparse Bayesian learning algorithm for EEG brain source localization[J]. Biomedical Signal Processing and Control, 2022, 77: 103838.

[11] Zheng N, Li Y, Shi W, et al. Sparse Bayesian based NARX modeling of cortical response: introducing information entropy for enhancing the stability[J]. Neurocomputing, 2025, 626: 129569.

[12] Santer P, Reinhard J, Schindler A, et al. Detection of localized bearing faults in PMSMs by means of envelope analysis and wavelet packet transform using motor speed and current signals[J]. Mechatronics, 2025, 106: 103294.

[13] Tao Y, Ge C, Feng H, et al. A novel approach for adaptively separating and extracting compound fault features of the in–wheel motor bearing[J]. ISA Transactions, 2025, 159: 337–351.

[14] Hu F, Zhi L, Zhou K, et al. A novel symplectic geometry–based modal decomposition technique for accurate modal identification of tall buildings with close–spaced modes[J]. Journal of Building Engineering, 2024, 95: 110047.

[15] Hao J, Ma L, Yin X, et al. Improved symplectic geometry mode decomposition based correlation method in white light scanning interferometry[J]. Optics and Lasers in Engineering, 2024, 182: 108482.

[16] Cai H, Yuan Z, Gao Y, et al. A multi–modal open dataset for mental–disorder analysis[J]. Scientific Data, 2022, 9: 178.

[17] Xia X, Wang X. Fault diagnosis of planetary gearbox based on hierarchical refined composite multiscale fuzzy entropy and optimized LSSVM[J]. Entropy, 2025, 27(5): 512.