

尺度自适应的多小波脑电稀疏时变建模 与时频表征方法

郑楠^{1,2}, 李玉榕^{1,2*}, 史武翔^{1,2}, 谭济宇^{1,2}, 陈文升^{1,2}

(1. 福州大学电气工程与自动化学院, 福建福州 350108; 2. 福建省医疗器械和医药技术重点实验室, 福建福州 350108)

摘要: 时频表征的准确性直接影响脑电信号内在含义和动态特性的解析. 针对基于多小波的时频表征方法中存在的尺度固定、回归项选择不当等问题, 本文提出一种基于尺度自适应稀疏多小波的时频表征框架, 以提升表征精度. 该方法通过稀疏贝叶斯学习-信息熵联合优化, 从全局角度筛选时变模型的最优回归项, 有效规避传统方法的局部收敛缺陷; 进一步, 为小波基分配尺度, 从最优个体、粒子群变异和种群更新3个方面改进遗传算法并进行尺度寻优, 实现小波基与最优尺度的自适应匹配, 增强多小波基对时变信号的拟合能力. 最终, 估计的时变参数经由参数谱估计转化为准确的时频表征. 在3个仿真模型的实验结果表明, 所提方法至少降低23.08%的时变参数估计误差, 增强2.93%的时频信息估计精度, 在动态参数跟踪和时频信息估计上展现出强大竞争力. 在BCI Competition II-data set III的实验结果显示, 所提方法在估计事件相关同步/去同步的性能较先进时变建模方法增强(3.37→8.78); 进一步将所提方法提取的时频信息与简单卷积神经网络结合, 即可在BCI Competition IV-data set 2b中取得与最先进但复杂的分类模型相当的识别准确率(88.04%), 侧面证实了所提方法的时频表征能力. 本文方法从模型结构筛选、寻优算法改进和基函数尺度配置3个方面进行设计, 实现时变参数估计准确率与时频分辨率的协同提升, 为脑电信号处理提供了一种新方法.

关键词: 运动想象脑电信号; 稀疏建模; 时变建模; 时频分析; 多尺度小波

基金项目: 国家自然科学基金(No.62373108)

中图分类号: TP391

文献标识码: A

文章编号: 0372-2112(2025)08-2707-12

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20250180

Sparse Time-Varying Modeling and Time-Frequency Representation of EEG Data Using Scale-Adaptive Multiwavelet

ZHENG Nan^{1,2}, LI Yu-rong^{1,2*}, SHI Wu-xiang^{1,2}, TAN Ji-yu^{1,2}, CHEN Wen-sheng^{1,2}

(1. College of Electrical Engineering and Automation, Fuzhou University, Fuzhou, Fujian 350108, China;

2. Fujian Key Laboratory of Medical Instrument and Pharmaceutical Technology, Fuzhou, Fujian 350108, China)

Abstract: The accuracy of time-frequency representation directly influences the interpretation of the intrinsic dynamics and functional significance of electroencephalogram (EEG) signals. To address the limitations of fixed scales and suboptimal regression term selection in existing multi-wavelet-based methods, this paper proposes a novel time-frequency representation framework based on scale-adaptive sparse multi-wavelets. This method adopts a joint sparse Bayesian learning and information entropy optimization framework to globally identify the optimal regression terms of the time-varying model, effectively avoiding the local convergence issues of traditional approaches. Furthermore, scales are allocated to the wavelet basis. The genetic algorithm is enhanced in three key aspects—optimal individual selection, particle swarm mutation, and population update—to optimize the scale. This achieves adaptive matching between the wavelet basis and the optimal scale, thus enhancing the fitting capability of multiple wavelet bases for time-varying signals. Ultimately, the estimated time-varying parameters are transformed into accurate time-frequency representations through parameter spectral estimation. Experiments on three simulation models show at least a 23.08% reduction in parameter estimation error and a 2.93% improvement in time-frequency resolution. Compared to state-of-the-art algorithms, it shows strong competitiveness in

tracking time-varying parameters and extracting time-frequency features. On BCI Competition II-data set III, our method enhances event-related desynchronization/event-related synchronization detection, with performance improving from 3.37 to 8.78. When combined with a simple convolutional neural network, it achieves 88.04% recognition accuracy on the BCI Competition IV-dataset 2b—comparable to that of more complex state-of-the-art models—thereby indirectly validating its effectiveness in time-frequency representation. Our method is designed from three perspectives: model structure optimization, algorithm enhancement, and basis function scaling. The collaborative improvement of time-varying parameter estimation and time-frequency resolution is successfully achieved, offering a novel methodology for EEG signal.

Key words: motor imagery electroencephalography; sparse modeling; time-varying modeling; time-frequency analysis; multi-scale wavelet

Foundation Item(s): National Natural Science Foundation of China (No.62373108)

1 引言

脑电信号(ElectroEncephaloGram, EEG)作为神经电活动的直接表征载体,凭借其非侵入的采集特点和高时间分辨率的优势,已经成为神经科学^[1]、脑机接口^[2]和临床诊断^[3]等领域的关键监测手段.然而,EEG信号能量微弱,且易受周围噪声干扰,难以从时域或频域中提取揭示信号内在含义的动态信息.时频联合分析技术通过融合时间与频率维度的动态特征,为解析EEG信号的瞬态节律变化提供了新途径,已在意图解码^[4]、病理机制探索^[5]等方面展现出强大的应用潜力.

当前研究中,短时傅里叶变换(Short-Time Fourier Transform, STFT)和连续小波变换(Continuous Wavelet Transform, CWT)等非参数方法被广泛使用,但其受限于固定窗长与基函数选择,难以平衡时频分辨率与能量泄露问题^[6].参数方法通过时变建模和频谱转换,能够得到比非参数方法更准确的时频表征结果,但如何准确估计时变参数是参数方法的重点与难点.现有方法包括两种:一是基于自适应算法,如递推最小二乘法或卡尔曼滤波器算法,但该类方法容易产生跟踪滞后,导致不准确的表征结果;另一种是基于基函数拓展的方法,该方法通过使用有限数量基函数的线性组合来表示时变系数,可以有效避免跟踪滞后问题.相比于传统的自适应参数谱估计或非参数谱估计方法,基于基函数拓展的参数谱估计方法即使在低信噪比数据中也能产生高分辨率的谱估计结果^[7].

常用的基函数主要包括径向基函数和小波基函数两种.径向基函数是具有中心对称性的距离函数,通过选择合适的尺度和核函数,可以获得较好的跟踪性能.单一尺度的径向基函数在跟踪多变信号时性能受限,相关研究利用粒子群算法进行尺度自适应寻优,增强了径向基函数的描述性能^[8];在此基础上,考虑了回归项的选择问题,进一步增强了模型的表述能力^[9];团队在前期的工作中设计了核函数相关参数的自适应选择方法,增强了时变参数估计的准确性,并转化为高分辨率的时频表示^[10].虽然径向基函数可以通过尺度调整

适应不同的信号,但其本质仍是一个平滑的函数;在逼近突变或常数信号时,其表现会弱于如Haar小波这类的非平滑函数,导致部分时频信息缺失.不同阶数的B样条小波具备不同的特性,如一阶和二阶的B样条适用突变信号,三阶到五阶的B样条适用平滑信号,因此,融合多阶B样条小波构成多小波基,能够克服径向基函数的缺点,有效跟踪缓慢平滑和快速突变的信号.将多小波基和稀疏表达结合的时变建模方法已在多个领域中被广泛应用.Xu等人^[11]基于稀疏多小波基估计时变广义拉盖尔-沃尔特拉模型中的非平稳参数,从脉冲活动中识别时变非线性神经动态系统.Wang等人^[12]将稀疏多小波基应用于癫痫患者的脑电信号建模中,从参数转化的时频图中提取信息特征,实现了癫痫的发作检测与分类.Liu等人^[4]在运动想象意图识别中将EEG信号利用稀疏多小波基表征,从中提取时频特征,提高运动想象解码的准确性.多小波基虽然具备跟踪不同类型信号的特性,但其尺度固定的特性会降低多小波基的灵活性,导致估计性能下降.针对该问题,Li等人^[13]将多个尺度的小波基结合,构成多尺度多小波基函数.但该方法是通过增加不同尺度的基函数来提高多小波基的性能,没有改变单一函数尺度固定的本质,这会导致描述不同时变信号时需要大量的小波基,极大地增加了计算的负担.此外,上述方法在考虑模型稀疏性时,均是利用前向正交回归方法挑选候选项,这种基于贪婪思想的做法可能会使结果陷入局部最优值.

为了解决上述难题,提高时变参数的估计精度,获得高分辨率的时频信息,本文对稀疏贝叶斯学习(Sparse Bayesian Learning, SBL)方法进行了优化改进,并在此基础上,设计了多小波基函数的尺度自适应匹配策略,提出了一种有效的稀疏时变建模与时频表征方法.具体而言,通过SBL和信息熵(Information Entropy, IE)的联合优化策略,实现回归项全局最优筛选,避免了传统方法陷入局部最优的问题.随后,为每个小波基分配尺度,并从最优个体策略、粒子群变异策略和种群更新策略3个方面改进遗传算法,提高尺度寻优的准确性,进一步增强了多小波基对时变信号的拟合性

能.在此基础上,利用最小二乘法估计并重构时变参数,结合参数谱估计方法转化为高分辨率的时频图.本文提供了一种更精确、分辨率更高的时频信息提取方法,能有效地捕捉时频变化过程中的细节信息,为后续脑电信号乃至非平稳信号的分析奠定基础.

2 方法

所提方法的流程如图 1 所示.脑电信号建模为时不变模型,并采用联合 SBL-IE 的稀疏建模策略提取重要模型项.根据所确定的模型项,将脑电信号表示为时变模型,并将模型的时变参数转化为 B 样条多小波基和时不变参数的乘积.为增强 B 样条多小波基的表达能力,给每个小波基分配尺度,并通过改进遗传算法确定最优尺度.结合优化后的多小波基和最小二乘法估计,时不变参数可被准确估计,并重构为时变参数.最终,经过参数谱估计方法,时变参数可转化为高分辨率时频结果.

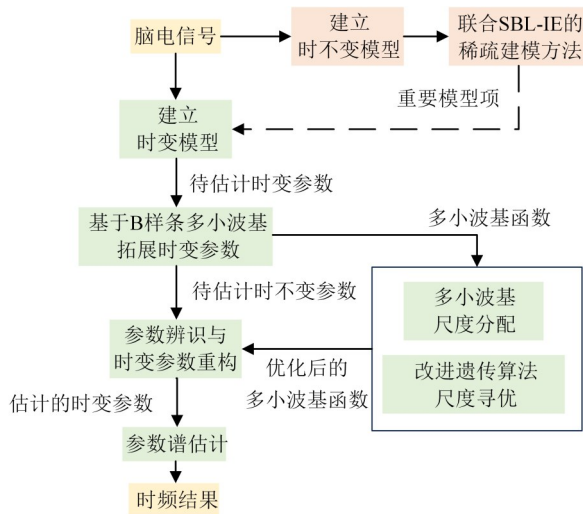


图 1 所提方法流程图

2.1 稀疏贝叶斯学习-信息熵联合的模型结构选择方法

在自回归模型中,回归项可能存在多重共线性及冗余项,导致最小二乘法参数估计的协方差矩阵病态,从而降低估计精度.传统前向正交回归策略因采用贪心搜索机制,在模型项选择过程中易陷入次优解收敛困境,且早期选择偏差会产生累积效应,限制后续优化空间.本文提出一种联合 SBL 与 IE 的全局优化策略,由 SBL 获得参数的动态更新矩阵,结合 IE 为每个模型项分配权重,从全局和动态的角度客观评价模型项的贡献.该方法解决了传统前向正交回归的局部优化限制,在保证参数估计一致性的同时提升了模型稀疏性.

具体而言,将脑电信号建模为时不变自回归模型:

$$y(t) = \sum_{i=1}^{q_1} \theta_i y(t-i) + e(t) = \Phi^T \theta + e(t) \quad (1)$$

其中, q_1 表示模型阶数, $\Phi = [y(t-1), y(t-2), \dots, y(t-q_1)]$, $\theta = [\theta_1, \theta_2, \dots, \theta_{q_1}]$.

应用 SBL 方法,第 $k+1$ 次迭代 ($k=1, 2, \dots, K, K$ 为最大迭代次数) 的稀疏参数可以由下列式子得到^[14]:

$$\hat{\theta}_{k+1} = (\Phi^T \Phi + \mu G^T G)^{-1} (\Phi^T y + \mu G^T (v_k + d_k)) \quad (2)$$

$$v_{k+1} = \max(0, (\hat{G}\theta_{k+1} - d_k) - \mu/\lambda_k) - \max(0, -(\hat{G}\theta_{k+1} - d_k) - \mu/\lambda_k) \quad (3)$$

$$d_{k+1} = d_k - (\hat{G}\theta_{k+1} - v_{k+1}) \quad (4)$$

其中, μ 是拉格朗日系数, G 是维度为 P 的单位方阵, v_k 和 d_k 为 q_1 行 1 列的 0 序列, λ 是正则化参数.

与现有 SBL 方法仅关注最终迭代结果的处理方法不同,本文保留 SBL 每次迭代的结果,并结合 IE 评估每个回归项的重要性:

$$H(i) = - \sum_{k=1}^K P(\text{nor}_{\theta_k}(i)) \log_2 P(\text{nor}_{\theta_k}(i)) \quad (5)$$

其中, $\text{nor}_{\theta_k}(i)$ 为第 i 个回归项的归一化结果, $P(\text{nor}_{\theta_k}(i))$ 为取值为 $\text{nor}_{\theta_k}(i)$ 时的概率.

由于采用稀疏贝叶斯方法,冗余项的参数将在几次迭代后置 0, 因此获得降低的熵值; 而重要候选项的熵值通常较大, 会被视为异常值. 为了提取重要模型项, 本文利用四分位数法确定异常值及对应的候选项, 这些候选项即为最终的回归项, 其数量即为最终的模型阶数.

2.2 多 B 样条小波基拓展的时变建模方法

基于上述重要模型项, 脑电信号可用时变自回归模型描述为

$$y(t) = \sum_{i=1}^{q_2} \theta_i(t) y_i(t) + e(t) \quad (6)$$

其中, $y(t) (t=1, 2, \dots, N, N$ 为采样数) 为脑电信号, y_i 表示重要模型项, q_2 是模型的阶数, $\theta_i (i=1, 2, \dots, q_2)$ 表示时变参数, $e(t)$ 是一个均值为 0、方差为 σ_e^2 的独立且正态分布的随机变量序列.

为了便于利用最小二乘法进行参数估计, 时变参数 $\theta_i(t)$ 可以表示为 M 阶基函数 $\varphi_m(t)$ 与时不变参数 $g_{i,m}$ 乘积的线性组合:

$$\theta_i(t) = \sum_{m=1}^M g_{i,m} \varphi_m(t) \quad (7)$$

当基函数选择为小波基时, 式(7)可用截断小波展开为

$$\theta_i(t) = \sum_{w \geq 0} \sum_{h \geq 0} l_{i,w,h} \Psi_{w,h}(t) \quad (8)$$

其中, w 和 h 分别为尺度因子和位移因子, $l_{i,w,h}$ 为时不变

参数, $\Psi_{w,h}(t)$ 为母小波基.

已有研究表明, 在多维和多分辨率拓展的情况下, B 样条小波基凭借其出色的数学特性, 相较于其他小波基, 在动态系统的参数辨识中展现出显著的性能优势^[15]. 基于此, 本文选择 B 样条基函数作为小波基.

B 样条小波基具有多阶性质, r 阶 B 样条小波可以表示为

$$\Psi_{w,h}^{(r)}(t) = 2^{w/2} B_r(2^w t - h) \quad (9)$$

其中, B_r 为 r 阶 B 样条函数, 其递归形式定义为

$$B_r(t) = \frac{t}{r-1} B_{r-1}(t) + \frac{r-t}{r-1} B_{r-1}(t-1) \quad (10)$$

当 $r=1$ 时, B 样条为 Harr 小波, 定义为

$$B_1(x) = \begin{cases} 1, & x \in [0, 1) \\ 0, & \text{other} \end{cases} \quad (11)$$

当 $\theta_i(t)$ 定义在 $[0, 1]$ 时, 尺度因子、位移因子和阶数满足下列关系:

$$\Gamma_r = \{h: -r \leq h \leq 2^w - 1\} \quad (12)$$

将式(8)和式(9)代入式(6)中, 可得

$$y(t) = \sum_{i=1}^{q_s} \sum_{w \geq 0} \sum_{h \in \Gamma_r} l_{i,h} \Psi_{w,h} \left(\frac{t}{N} \right) y_i(t) + e(t) \quad (13)$$

多小波理论研究表明, 当 r 取值为 $[2, 3, 4]$ 时, 其生成的混合阶数多小波基可以实现不同阶基函数之间的优势互补^[4]. 因此, 本文利用多小波基来描述脑电信号, 公式(13)可由多小波基重新表述为

$$y(t) = \sum_{i=1}^{q_s} \sum_{w \geq 0} \sum_{r=2}^4 \sum_{h \in \Gamma_r} l_{i,h}^{(r)} \Psi_{w,h}^{(r)} \left(\frac{t}{N} \right) y_i(t) + e(t) \quad (14)$$

2.3 基于改进遗传算法的尺度自匹配方法

多小波基方法虽然提高了对信号的跟踪能力, 但每个函数尺度固定的局限仍会使其无法有效捕捉信号的关键细节成分. 为了解决这些难题, 本文提出了一种尺度自匹配方法. 该方法根据最小阶基函数的位移因子数目统一不同阶基函数的数目, 并为具有相同位移因子的基函数分配同一尺度. 同时, 从 3 个方面改进遗传算法, 促进尺度寻优, 实现基函数和最优尺度的自适应匹配, 提高多小波基对不同信号的描述能力. 改进遗传算法的流程如图 2 所示.

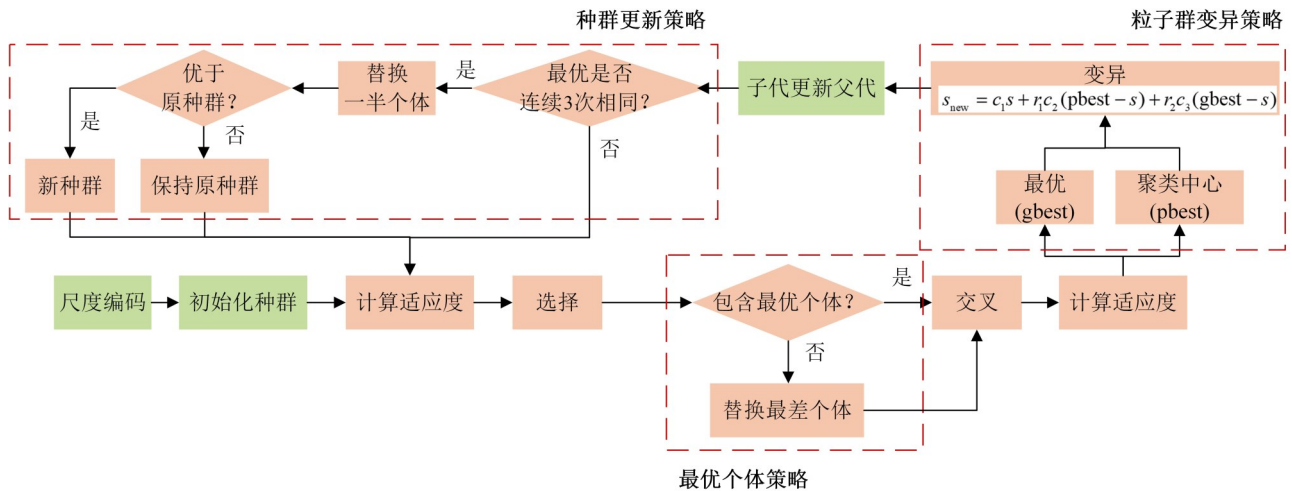


图2 改进遗传算法流程图

从图 2 可知, 本文对遗传算法的改进包括最优个体策略、粒子群变异策略和种群更新策略 3 个方面. 为了避免传统方法在选择操作中遗漏最优个体, 本文记录种群的最优个体, 当最优个体未被选入下一代时, 利用最优个体替换子代种群中的最差个体; 在变异操作方面, 本文引入粒子群思想, 通过群体最优与团体信息指导变异方向. 交叉后的种群根据适应度的大小聚类为高、中、低 3 个团体, 记录群体最优 (gbest) 和每个团体的中心; 随后, 个体 s 根据下式进行变异:

$$s_{\text{new}} = c_1 s + r_1 c_2 (\text{pbest} - s) + r_2 c_3 (\text{gbest} - s) \quad (15)$$

其中, $c_1 \sim c_3$ 分别表示对当前状态的继承程度、个体受团体的影响程度以及个体受整个种群的影响程度. 根据

经验, c_1 从 0.9 开始, 随迭代次数均匀降低到 0.4, c_2 和 c_3 取值为 1.5, r_1 和 r_2 表示 0~1 的随机数; pbest 表示个体 s 对应的团体中心; 若变异后某位数值不在 $[0.1, 2]$ 内, 则替换为距离最近的上限或下限.

此外, 为避免遗传算法过早陷入局部最优, 本文还增加了种群更新策略. 当连续 3 次迭代的最优均方根误差相等时, 将当前种群适应度较差的一半个体替换为随机个体, 并进行一轮迭代; 若新种群的最优个体优于原种群的最优个体, 则替换有效; 反之, 则采用原种群继续.

2.4 参数谱估计公式

基于上述建模过程, 可以得到准确估计的时变参

数 $\theta_i(t)$, 利用参数谱估计可将其转化为时频图^[16].

$$\text{PSD}(t, f) = \frac{\hat{\delta}_e^2}{\left| 1 - \sum_{i=1}^{q_2} \hat{\theta}_i(t) e^{-2j\pi f t} \right|^2} \quad (16)$$

其中, $j = \sqrt{-1}$, f_s 为采样频率, $\hat{\delta}_e^2$ 是估计误差的方差. 值得注意的是, 式中的谱函数是频率 f 的连续函数, 可以用于评估 $[0, f_s/2]$ 间任何期望频率处的谱估计.

3 性能测试与方法评估

本文方法在 3 个仿真模型和 2 个包含左右手运动想象任务的真实脑电数据集中进行性能验证, 所用数据的具体信息总结如下.

3.1 时变参数仿真模型

准确估计时变参数是后续时频估计的基础. 由于时变参数是基于相同的基函数估计得到, 估计多类型的时变参数更能验证所设计基函数的性能. 因此, 本文的验证将利用两个时变参数包含多种类型信号的仿真模型进行, 一个是多种类型的信号混合在同一个时变参数中, 另一个是仿真模型中包含多个时变参数, 每个参数由不同类型的信号构成, 具体结构如下.

3.1.1 混合时变仿真模型

$$y(n) = a_1(n)y(n-1) + a_2(n)y(n-2) + e(n) \quad (17)$$

其中, $y(n)$ 为第 n 个脑电观测样本, $e(n)$ 是一个均值为 0、方差为 δ_e^2 的独立且正态分布的随机变量序列, $a_1(n)$ 和 $a_2(n)$ 为系统的时变参数, 具体形式为

$$\begin{cases} a_1(n) = 2\cos(2\pi g(n)), n = 1, 2, \dots, N \\ a_2(n) = -1, n = 1, 2, \dots, N \end{cases} \quad (18)$$

$g(n) =$

$$\begin{cases} 0.24 & n = 1, 2, \dots, 2/N \\ 0.15 - 0.1\sin\left(2\pi \frac{n-2/N}{N-(2/N+1)}\right) & n = 2/N+1, 2/N+2, \dots, N \end{cases} \quad (19)$$

3.1.2 多时变仿真模型

$$\begin{aligned} y(n) = & a_1(n)y(n-1) + a_2(n)y(n-2) \\ & + a_3(n)y(n-3) + e(n) \end{aligned} \quad (20)$$

其中, 符号 n 和 $e(n)$ 的定义不变, 时变参数的定义如下:

$$a_1(n) = 0.5\cos(4\pi n/N) \quad (21)$$

$$a_2(n) = \begin{cases} 0.3, & 1 \leq n < 1/(4N) \\ -0.1, & 1/(4N) \leq n < 2/(4N) \\ 0.3, & 2/(4N) \leq n < 3/(4N) \\ -0.1, & 3/(4N) \leq n \leq N \end{cases} \quad (22)$$

$$a_3(n) = 0.6 \quad (23)$$

为了验证算法在不同条件下的精度, 设置两种条件下的仿真数据: 一是固定信号长度为 1000, 信噪比从 5 dB 开始, 间隔为 5, 增加到 20 dB; 二是固定信噪比为 20 dB, 信号长度从 200 开始, 间隔为 200, 增加到 1000.

算法的精度利用平均绝对误差 (Mean Absolute Error, MAE) 和标准根均方差 (Normalized Root Mean Squared Error, NRMSE) 评估, MAE 和 NRMSE 越小, 表明估计精度越高, 具体公式如式 (24) 和式 (25) 所示:

$$\text{MAE} = \frac{1}{N} \sum_{n=1}^N |\hat{a}(n) - a(n)| \quad (24)$$

$$\text{NRMSE} = \sqrt{\frac{1}{N} \sum_{n=1}^N \frac{|\hat{a}(n) - a(n)|^2}{|a(n)|^2}} \quad (25)$$

3.2 包含特定脑电频率的仿真模型

在时变参数估计的基础上, 进一步地, 建立包含多个频率成分的仿真模型, 用以验证所提方法时频估计的准确性, 具体公式如式 (26) 和式 (27) 所示:

$$y'(n) = \begin{cases} 2|n|^\xi \sin(2\pi f_\theta n) + 2|n|^\xi \sin(2\pi f_\beta n), & n \in (0, 2) \\ |n|^\xi \sin(2\pi f_\alpha n) + |n|^\xi \sin(2\pi f_\gamma n), & n \in [2, 4) \\ 2|n|^\nu \sin(2\pi f_\alpha n), & n \in [4, 5) \\ |n|^\xi \sin(2\pi f_\alpha n) + |n|^\xi \sin(2\pi f_\gamma n), & n \in [5, 6) \\ 2|n|^\nu \sin(2\pi f_\gamma n), & n \in [6, 8) \end{cases} \quad (26)$$

$$y(n) = y'(n) + e(n) \quad (27)$$

其中, $\xi=0.5$, $\nu=0.25$. EEG 主要包含 5 种频段: δ 波 (1~4 Hz)、 θ 波 (4~8 Hz)、 α 波 (8~13 Hz)、 β 波 (13~30 Hz) 和 γ 波 (>30 Hz), 本文不考虑与深度昏迷相关的 δ 波^[17], 根据剩余频段的取值范围设置模型的频率参数: $f_\theta=6$ Hz, $f_\alpha=12$ Hz, $f_\beta=25$ Hz, $f_\gamma=40$ Hz. 对于时频估计, 我们关注的是目标频段能否准确激活, 以及非目标频段能否被较少的误估计. 因此, 本文利用目标频段的激活时长与非目标频段的激活时长的比值作为评估的指标, 当目标频段激活时长越多时, 误估计越小, 指标越大.

$$\text{percent} = \frac{t_{\text{aim}}}{t_{\text{no_aim}}} \times 100\% \quad (28)$$

其中, t_{aim} 和 $t_{\text{no_aim}}$ 分别表示目标时间段的激活时长和非目标时间段的激活时长.

3.3 真实脑电数据

为了验证所提方法估计真实脑电时频信息的能力, 我们选取了两个公开的左右手运动想象脑电数据集进行测试. 左右手运动想象诱发的大脑皮层神经振荡在时频域呈现出显著的跨半球调控规律: 对侧主感觉运动皮层 α 节律 (8~13 Hz) 和 β 节律 (18~25 Hz) 振幅降低, 出现事件相关去同步 (Event-Related Desynchronization, ERD), 而同侧相同区域的 α 、 β 节律振幅增加, 出现事件相关同步 (Event-Related Synchronization,

ERS)^[18]. 这种 ERD/ERS 现象可以为评估所提方法在捕捉关键神经生理活动动态变化方面的性能提供公认且可靠的“金标准”. 同时, 所提方法能否准确刻画这种

ERD/ERS 动态模式, 也直接关系到其在运动意图解码和相关神经功能临床评估中的潜在应用价值. 基于以上考虑, 本文选用的数据集总结在表 1 中.

表 1 所用数据集介绍

数据集名称	受试者数量	采样频率	采样通道	运动想象时间	数据处理	类别数量	重复次数
BCI Competition II -data set III ^[19]	1	128 Hz	C3,Fz,C4	3~8 s	0.5~30 Hz 带通	2	280
BCI Competition IV -data set 2b ^[20]	9	250 Hz	C3,Fz,C4	3~7 s	0.5~100 Hz 带通 50 Hz 陷波	2	680~760

C3 和 C4 通道已被证实能够最大程度地反映运动想象期间大脑的状态变化信息^[21], 因此本文使用 C3 和 C4 通道进行 ERD/ERS 现象的分析与应用.

4 实验结果

4.1 时变模型的参数估计结果

准确估计时变参数是后续时频估计的基础. 为了验证本文方法在该方面的性能, 本文引入 5 种对比方法, 包括最小二乘法、多尺度径向基、自适应径向基、稀疏多小波和多尺度多小波, 各方法的参数按照相关论文进行设置, 并根据不同信号做相应调整. 本文进行 10 次重复试验, 图 3 展示了不同方法对混合类型时变参数的估计示意图和指标平均值.

从图 3 的结果可知, 不论是对常数的估计, 还是对

突变和正弦的估计, 所提方法均与标准值保持高度一致, 取得了最小的 MAE 和 NRMSE 值, 比先进方法的最低误差降低了 23.08%. 与基于基函数拓展的方法相比, 最小二乘法产生了明显的滞后, 这说明基于基函数拓展的方法在描述时变系统上拥有比自适应方法更大的优势. 除本文所提方法外, 基于径向基函数的方法取得了比基于小波基更好的结果, 这可能是由于前者使用了更多数量的基函数. 在这种条件下, 本文方法为单个小波自适应地设置了尺度, 提高了多小波基的灵活性, 使其能在使用更少基函数的条件下获得更准确的跟踪性能. 同时, 虽然多尺度多小波方法和本文方法都考虑了小波基的尺度问题, 但多尺度多小波方法中单个小波的尺度仍是固定的, 限制了其跟踪多变信号的性能, 因此其估计精度低于本文方法.




图 3 不同方法在时变混合仿真模型的跟随示意图及对比结果

为了进一步验证所提方法对时变参数的跟踪性能, 本文利用多时变仿真模型进行 10 次重复实验, 与先进方法的对比结果展示在图 4 和表 2 中.

分析图 4 可知, 所提方法除了在正弦波峰值的跟随表现不如多尺度径向基外(图 4(b)和图 4(f)), 主要体现在第 250 点和第 500 点处, 均优于其他方法. 表现较差的原因可能是算法选择较小的尺度, 以适应方波和常值信号的估计, 这一点可以从二者对方波和常值的估计结果中看出. 多尺度径向基在第 250 点处对常值的估计误差远大于本文所提方法; 在第 500 点处, 二者对

方波和常值的估计误差相似, 但多尺度径向基的波形更平缓, 表明有更多的点偏离标准值. 从表 2 中可知, 本文所提方法取得了最优的估计结果, 降低了 57.14% 的估计误差. 联合图 3 和图 4 分析, 可发现一些相似的结论, 如最小二乘法在估计中会存在滞后现象, 导致较低的估计精度; 基于径向基方法的估计性能优于未考虑尺度的小波基方法等. 在多时变仿真模型中, 考虑了尺度因素的小波基方法展现出了更强大的跟踪性能. 本文方法考虑了小波基尺度的自适应性, 因此性能优于多尺度多小波方法.

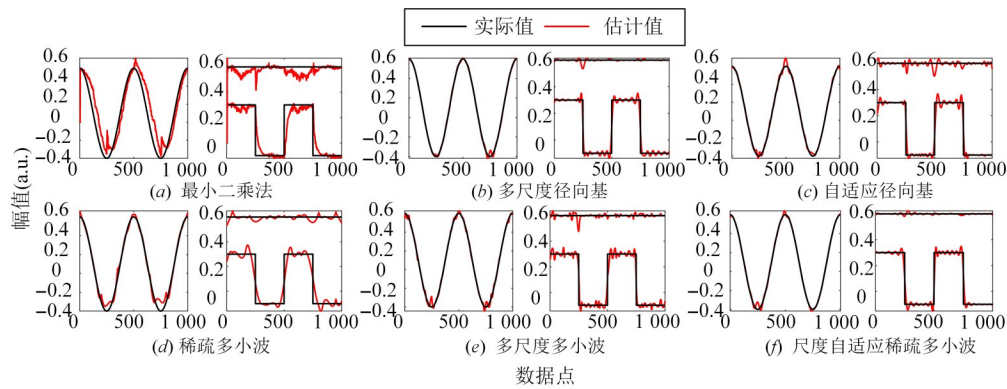


图4 不同方法在多时变仿真模型的跟随示意图

表2 不同方法在多时变仿真模型的结果

方法	MAE	NRMSE
最小二乘法	0.19±0.002	89.42±0.69
多尺度径向基 ^[8]	0.03±0.002	2.48±0.26
自适应径向基 ^[10]	0.04±0.001	3.17±0.29
稀疏多小波 ^[4]	0.08±0.001	12.82±0.36
多尺度多小波 ^[13]	0.04±0.001	1.85±0.15
尺度自适应稀疏多小波	0.02±0.001	0.79±0.09

注:加粗部分为最优结果.

为了验证所提方法的鲁棒性,本文进行变信噪比和变长度的实验,不同时变建模方法的结果如图5和图6所示.

从图5和图6中可知,信号长度和信噪比与估计误差均成反比.在信号长度为200的条件下,本文所提方法在混合时变仿真模型中的估计误差大于稀疏多小波方法,这可能是因为长度不足,遗传算法不能寻找最优的尺度,导致估计精度降低.而在其余的长度中,所提方法在混合时变仿真模型和多时变仿真模型中均取得了最优的估计结果.在不同信噪比的条件下,除了在SNR=5 dB时所提方法的估计误差大于多尺度径向基方法外,在其他的所有信噪比、所有模型中均取得最优的估计结果.综合长度因素和信噪比因素的结果,本文所提方法能在这两种因素的干扰下均取得最好的检测精度,表明算法具有良好的鲁棒性和估计准确性.




图5 信号长度对不同算法的影响(SNR=20 dB)




图6 信噪比对不同算法的影响(信号长度为1000个数据点)

4.2 包含特定脑电频率仿真模型的估计结果

在确定本文所提算法能够准确估计时变参数的基础上,进一步地,对其时频表征的能力进行评估. 在原有对比方法的基础上,增加了短时傅里叶变换和连续小波变换两种非参数时频估计方法. 不同方法对包含特定脑电频率的仿真模型的估计结果如图7和表3所示.

从图7可知,参数方法(图7(c)~图7(h))虽然会出现少估计现象(如图7(f)中2~2.5 s的25 Hz处),但其误估计的现象较少. 相比之下,非参数方法[图7(a)和图7(b)]则会对时频信息产生较多的误估计[如图7(b)中6~8 s的38~40 Hz处],导致较低的时频估计精度. 在参数方法中,最小二乘法 and 自适应径向基法对时频信息的误估计较多,但自适应径向基法对目标段的估计较为完全. 相比之下,基于多小波的方法对时频信息的误估计较少,对目标段的估计较为准确,实现了误估计和准确估计间的良好平衡. 为了定量描述不同方法的估计结果,利用公式(28)的评估得分如表3所示.

如表3所示,本文所提方法获得了最高的占比,比

表3 时频估计结果的量化指标 单位:%

方法	得分
短时傅里叶变换	69.36
连续小波变换	53.64
最小二乘法	72.13
多尺度径向基 ^[8]	76.36
自适应径向基 ^[10]	85.57
稀疏多小波 ^[4]	88.76
多尺度多小波 ^[13]	80.20
尺度自适应稀疏多小波	91.69

注:加粗部分为最优结果.

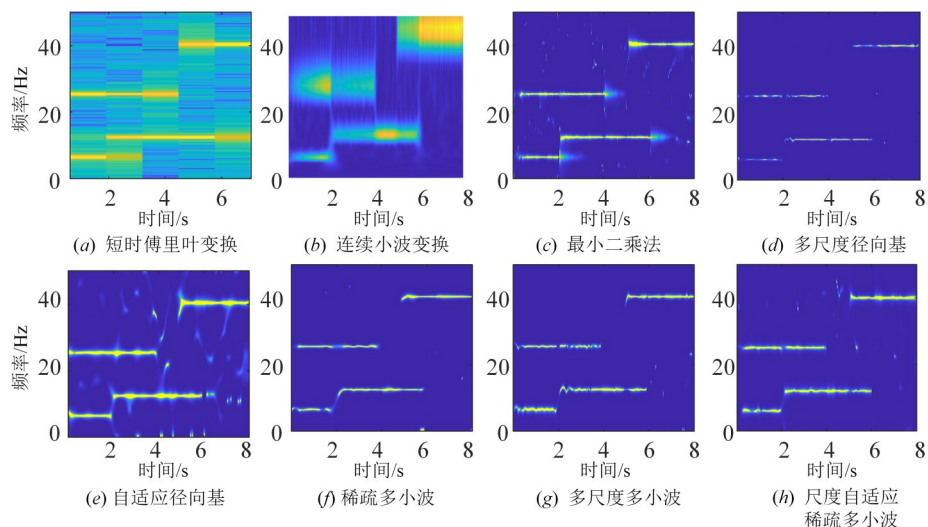


图7 不同方法对包含特定脑电频率仿真模型的时频估计结果

最优的稀疏多小波结果高出2.93%,表明所提方法能够实现误估计和准确估计的最优平衡. 基于多小波方法的平均得分(87.55%)高于其余方法,说明多小波基能结合不同阶数基函数的特性,更好地描述多变的时变参数,进而误估计更小. 对于目标段的估计,自适应径向基方法的估计结果最为完整,但其误估计的时段较多,导致其有效占比降低.

4.3 真实脑电信号ERD/ERS捕获结果

在仿真信号中证实方法的有效性后,将其应用于BCI Competition II-data set III数据集中,验证其对ERD/ERS的捕获性能,结果如图8所示.

从图8可知,当想象左手运动时,C3的8~13 Hz频段在3~8 s内激活增加(ERS现象),而C4通道在相应时间相应频段内未有明显激活(ERD现象);同样,在想象右手运动时,也能观察到ERD/ERS的现象,这表明所提方法能够解释信号所包含的有效信息.

为了进一步验证所提方法对ERD/ERS的捕捉能力,本文对比不同方法在想象左手运动时的ERD/ERS捕捉能力,其可视化结果展示在图9中.

从图9可知,短时傅里叶变换和最小二乘法在C3和C4通道都呈现出较大的激活,且激活未匹配目标时间(3~8 s),表明这两种方法对于ERD/ERS的现象的捕捉能力不足,这可能是由窗函数的限制和时变参数估计滞后所导致的. 剩余方法均能较好地捕获ERD/ERS的现象,但连续小波变换方法中C4通道在3~8 s内激活偏大,表明该方法可能对ERD/ERS现象描述能力不足. 基于基函数拓展的方法表现出了更好的性能,其中多尺度径向基方法和本文方法在C3通道展现了更大的激活,且本文方法在C4的激活更少,说明了本文方法的优势.




图8 想象左右手运动时 C3 和 C4 的时频图

参考 ERD/ERS 特性与公式(28),本文利用运动想象期间(3~8 s)双侧大脑目标频段能量的比值作为评估指标,记为 score. score 越大,表明算法对 ERD/ERS 现象的捕获能力越好. 定量分析结果展示在表 4 中.

从表 4 中可知,本文所提方法取得了最高的评分,比现有方法的最高得分还增加了 5.41 分,这得益于对正确回归项的检测和合适尺度的选择,使得准确估计的时变参数能够转换为更精确和更高分辨率的时频结果. 还可以发现,基于基函数拓展的方法取得了比非参数法和自适应参数法更高的得分,说明了参数谱估计方法的优势.

4.4 真实脑电信号运动想象分类结果

进一步地,我们在 BCI Competition IV-data set 2b 数据集上应用所提方法. 为了减少数据量,取每次提示前 2 s 到后 4 s 的数据进行分析,9 名受试者右手运动想象时的时频图如图 10 所示. 在 9 名受试者的结果中均能

表 4 不同方法对 ERD/ERS 现象捕获能力的评估结果 单位:分

方法	得分
短时傅里叶变换	0.63
连续小波变换	1.05
最小二乘法	1.38
多尺度径向基 ^[8]	1.53
自适应径向基 ^[10]	2.03
稀疏多小波 ^[4]	2.89
多尺度多小波 ^[13]	3.37
尺度自适应稀疏多小波	8.78

注:加粗部分为最优结果.

观察到,C3 通道在 8~13 Hz 和 18~25 Hz 频段存在 ERD 现象,C4 通道则存在 ERS 现象,但 C4 通道的 ERS 现象更为明显,且激活区域主要集中在 8~13 Hz 频段.

在获得时频结果的基础上,参考文献[22]中的做法,区分时频图的实部和虚部,将实部和虚部分别进行垂直拼接,作为输入送进卷积神经网络(Convolutional Neural Network, CNN)进行训练(具体设置可见文献[22]). 为了说明方法的优越性,除了对比文献[22]的方法(CWT+CNN)之外,还增加 MSCFormer^[23]、NF-EEG^[24]、TSE-DA-AWS^[25]这 3 种先进方法进行对比验证. 其中,MSCFormer 方法在数据增强的基础上,通过整合多个 CNN 分支实现多尺度特征提取,并采用 Transformer 模块捕捉全局依赖关系;NF-EEG 方法将输入进行重塑,并利用两种数据增强方法增加数据量,随后通过训练并融合多个 CNN 实现分类;TSE-DA-AWS 方法融合了双分支的时空嵌入模块、时空动态聚合模块和自适应加权频谱模块,增强对 EEG 信号时-空动态关联

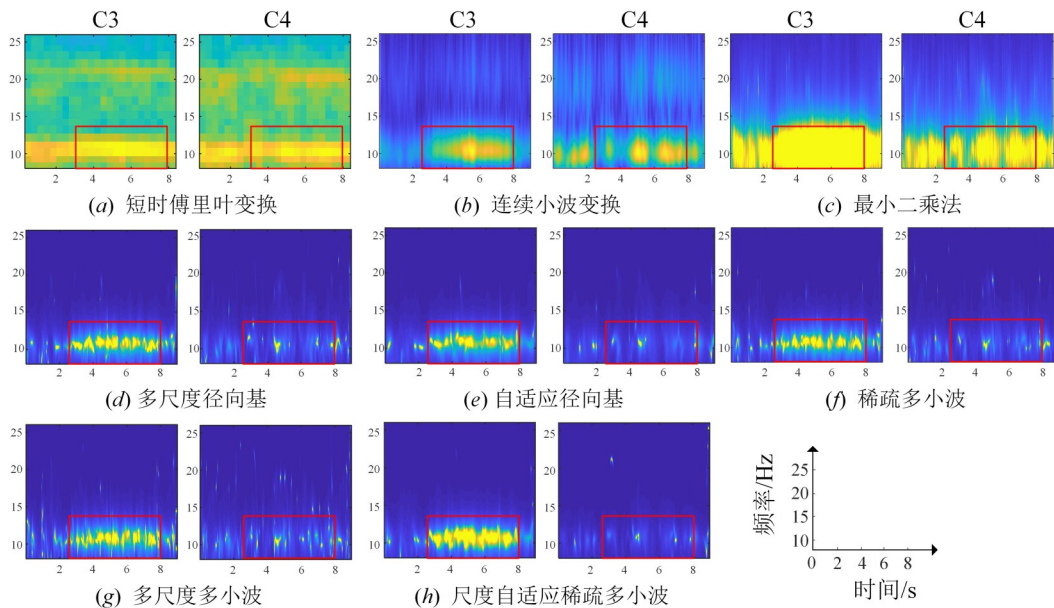


图9 想象左手运动时不同方法对 ERD/ERS 的估计可视图

特性和光谱特征的关注。

与先进方法的对比结果如表5所示,所提方法的识别正确率为 10×10 折交叉验证的平均值。同时,利用 Shapiro-Wilk 检验确定结果的正态性后,与所提方法进行配对样本 t 检验。

从表5中可知,所提方法仅使用两个通道的脑电数据,便在分类性能上显著优于使用全部通道的参考方法 CWT+CNN ($p=0.000\ 49 < 0.001$),表明所提方法能够

更准确地捕捉左右手运动想象的时频特征。此外,所提方法分类性能与 MSCFormer、NF-EEG 和 TSE-DA-AWS 相当 ($p > 0.05$),这些方法均需要较为复杂的数据处理和网络结构才能保证识别正确率。而本文方法专注于脑电信号的高分辨率和高准确率时频表征,仅结合结构简单的 CNN 便取得了与这些先进方法相当的性能,进一步验证了其在时频信息提取方面的有效性。后续将结合时频特性,设计更优的分类模型,进一步提高分类性能。

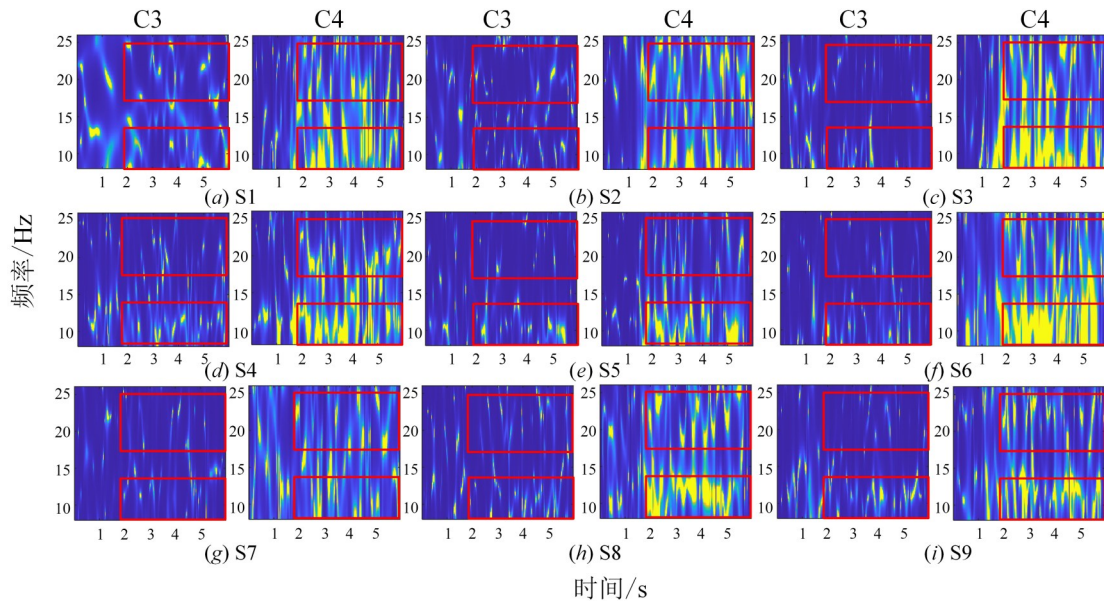


图10 想象右手运动时不同受试者对ERD/ERS的估计可视图

表5 不同方法对BCI Competition IV-data set 2b数据的分类结果

单位:%

方法	S1	S2	S3	S4	S5	S6	S7	S8	S9	平均
MSCFormer ^[23]	78.60	71.21	82.75	96.25	99.81	87.81	94.00	94.75	88.88	88.00
NF-EEG ^[24]	82.46	75.47	78.70	96.74	98.53	86.85	91.61	95.04	90.24	88.40
TSE-DA-AWS ^[25]	88.33	74.85	75.00	97.97	95.67	89.44	90.55	87.10	86.94	87.32
CWT+CNN ^[22]	74.00	68.00	67.80	92.30	79.40	78.10	87.40	79.00	78.30	78.30*
所提方法	80.56	73.37	84.52	95.95	95.24	86.11	92.63	95.11	88.89	88.04

注:*表明进行配对样本 t 检验时,与所提方法存在显著性差异。

5 结论

本文提出了一种基于尺度自适应的多小波稀疏时变建模与时频表征方法,旨在提高脑电信号的时频表征能力。通过构建时变仿真模型和包含特定脑电频率的仿真模型,分别验证该方法在时变参数估计和时频表征方面的能力。结果表明,该方法在参数估计精度、鲁棒性以及时频表征准确性等方面均优于先进算法。在仿真模型中验证有效性后,将该方法应用于 BCI Competition II-data set III 和 BCI Competition IV-data set 2b 中,分别从 ERD/ERS 表征能力和分类准确率两方面

证实了所提方法的优越性与实用性。综上所述,本文方法建立了稀疏表示与参数估计协同优化的非平稳信号处理范式,为脑电信号处理领域的瞬态特征解析开辟了新的技术路线。

未来的工作重点是提升算法效率和优化分类模型,以拓宽算法的适用范围,并提高其在实际场景中的应用性能。

参考文献

- [1] ZHENG N, LI Y R, SHI W X, et al. Sparse Bayesian based NARX modeling of cortical response: Introducing informa-

- tion entropy for enhancing the stability[J]. *Neurocomputing*, 2025, 626: 129569.
- [2] 康冉澜, 李玉榕, 史武翔, 等. 基于 Dempster-Shafer 证据推理的 EEG-fNIRS 运动想象分类决策层融合方法[J]. *电子学报*, 2025, 53(3): 941-950.
KANG R L, LI Y R, SHI W X, et al. Decision-level fusion of EEG-fNIRS for motor imagery classification based on dempster-shafer evidence reasoning[J]. *Acta Electronica Sinica*, 2025, 53(3): 941-950. (in Chinese)
- [3] CAI N Q, SHI W X, CHEN R K, et al. Cerebral-cerebellar cortical activity and connectivity underlying sensory trick in cervical dystonia[J]. *Annals of Clinical and Translational Neurology*, 2024, 11(10): 2633-2644.
- [4] LIU Z F, WANG L N, XU S, et al. A multiwavelet-based sparse time-varying autoregressive modeling for motor imagery EEG classification[J]. *Computers in Biology and Medicine*, 2023, 155: 106196.
- [5] MI Y J, LIN A J. Spectral time-varying pattern causality and its application[J]. *IEEE Journal of Biomedical and Health Informatics*, 2024, 28(6): 3742-3749.
- [6] TANG B W, DING Y P, PENG Y Q, et al. Target localization algorithm based on improved short-time Fourier transform[J]. *Digital Signal Processing*, 2024, 155: 104734.
- [7] ZHAO H F, GUI L. Nonparametric and parametric methods of spectral analysis[J]. *MATEC Web of Conferences*, 2019, 283: 07002.
- [8] LI Y, LIU Q, TAN S R, et al. High-resolution time-frequency analysis of EEG signals using multiscale radial basis functions[J]. *Neurocomputing*, 2016, 195: 96-103.
- [9] LI Y, CUI W G, HUANG H, et al. Epileptic seizure detection in EEG signals using sparse multiscale radial basis function networks and the Fisher vector approach[J]. *Knowledge-Based Systems*, 2019, 164: 96-106.
- [10] ZHENG N, LI Y R. Adaptive radial basis functions based time-varying model for EEG analysis in patients with cervical dystonia[J]. *Biomedical Signal Processing and Control*, 2024, 92: 106135.
- [11] XU S, LI Y, HUANG T W, et al. A sparse multiwavelet-based generalized laguerre-Volterra model for identifying time-varying neural dynamics from spiking activities[J]. *Entropy*, 2017, 19(8): 425.
- [12] WANG Q H, WEI H L, WANG L N, et al. A novel time-varying modeling and signal processing approach for epileptic seizure detection and classification[J]. *Neural Computing and Applications*, 2021, 33(11): 5525-5541.
- [13] LI Y, CUI W G, LUO M L, et al. High-resolution time-frequency representation of EEG data using multi-scale wavelets[J]. *International Journal of Systems Science*, 2017, 48(12): 2658-2668.
- [14] LIU Z P, TANG X Q, WANG X F, et al. Wind turbine blade bearing fault diagnosis under fluctuating speed operations via Bayesian augmented Lagrangian analysis[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(7): 4613-4623.
- [15] CHEN S, HONG X, KHALAF E F, et al. Comparative performance of complex-valued B-spline and polynomial models applied to iterative frequency-domain decision feedback equalization of Hammerstein channels[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28(12): 2872-2884.
- [16] ZHANG Z G. Spectral and time-frequency analysis[M]// *EEG Signal Processing and Feature Extraction*. Singapore: Springer Singapore, 2019: 89-116.
- [17] SHARMA R, MEENA H K. Emerging trends in EEG signal processing: A systematic review[J]. *SN Computer Science*, 2024, 5(4): 415.
- [18] SOLLFRANK T, KOHNEN O, HILFIKER P, et al. The effects of dynamic and static emotional facial expressions of humans and their avatars on the EEG: An ERP and ERD/ERS study[J]. *Frontiers in Neuroscience*, 2021, 15: 651044.
- [19] BLANKERTZ B, MÜLLER K R, CURIO G, et al. The BCI competition 2003: Progress and perspectives in detection and discrimination of EEG single trials[J]. *IEEE Transactions on Bio-Medical Engineering*, 2004, 51(6): 1044-1051.
- [20] LEEB R, BRUNNER C, MÜLLER-PUTZ G, et al. BCI competition 2008-Graz data set B[J]. *Graz University of Technology*, 2008, 16: 1-6.
- [21] YAACOUB C, MHANNA G, RIHANA S. A genetic-based feature selection approach in the identification of left/right hand motor imagery for a brain-computer interface[J]. *Brain Sciences*, 2017, 7(1): 12.
- [22] KIM J, PARK Y, CHUNG W. Transform based feature construction utilizing magnitude and phase for convolutional neural network in EEG signal classification[C]// *2020 8th International Winter Conference on Brain-Computer Interface*. Piscataway: IEEE, 2020: 1-4.
- [23] ZHAO W, ZHANG B C, ZHOU H F, et al. Multi-scale convolutional transformer network for motor imagery brain-computer interface[J]. *Scientific Reports*, 2025, 15: 12935.
- [24] ARI E, TAÇGIN E. NF-EEG: A generalized CNN model

for multi class EEG motor imagery classification without signal preprocessing for brain computer interfaces[J]. *Biomedical Signal Processing and Control*, 2024, 92: 106081.

[25] YAN W D, LIU J Y, LUO J, et al. A temporal-spatial em-

bedding and dynamic aggregation network with adaptive weighting spectrum for EEG motion intention recognition[J]. *IEEE Transactions on Instrumentation and Measurement*, 2025, 74: 4007611.

作者简介



郑楠 男, 1996年11月出生于广东省饶平县. 现为福州大学电气工程与自动化学院博士研究生. 主要研究方向为生物医学信号的建模与分析.

E-mail: zn190120078@163.com



李玉榕 女, 1973年2月出生于福建省莆田市. 现为福州大学电气工程与自动化学院教授、博士生导师. 主要研究方向为多模态电生理信号建模与智能康复技术.

E-mail: liyurong@fzu.edu.cn