DOI: 10.13382/j.jemi.B2407331

多通道权重融合和小波分解的癫痫棘波检测方法*

俞小彤[1] 赵若辰[1] 宁晓琳[1,2]
(1. 北京航空航天大学仪器科学与光电工程学院 北京 100191;
2. 杭州极弱磁场国家重大科技基础设施研究院 杭州 310051)

摘 要:脑电的棘波自动化检测是目前研究的重点,对癫痫诊断具有重要意义。现有检测方法主要有两类:信号分析和机器学习。前者对异常值敏感,后者算法对不同数据的鲁棒性未能得到充分验证。另外,传统的基于单通道脑电的棘波检测方法容易受到伪迹干扰。针对现有算法存在的问题并结合棘波的电生理特点,提出了基于多通道数据权重融合和小波分解的棘波检测算法。首先,根据癫痫棘波的放电特性,设计一种以幅值和波形趋势为特征值的多通道权重融合方法,获得棘波数据强化后的单通道数据;其次,算法引入小波分解,有效地提取信号中的局部特征,增强检测癫痫棘波这类具有突变特性信号的能力;最后,通过临床采集的癫痫患者脑电数据,验证了该算法能实现癫痫发作间期棘波的精确检测,诊断准确率可达 92.3%以上。相较于传统的单通道脑电棘波检测方法,该方法具有检测准确率高、计算简单的优势,是一种有效的癫痫发作间期的棘波检测技术。

关键词: 脑电信号;多通道权重融合;小波分解;模极大值;棘波检测
中图分类号: TN911.72 **文献标识码**: A **国家标准学科分类代码**: 510.40

Multichannel weight fusion and wavelet decomposition method for detecting epileptic spines

Yu Xiaotong[1] Zhao Ruochen[1] Ning Xiaolin[1,2]
(1. School of Instrumentation and Optoelectronic Engineering, Beihang University, Beijing 100191, China;
2. Hangzhou Institude of Extremely-weak Magnetic Field Major National Science and Technology Infrastructure, Hangzhou 310051, China)

Abstract: The automated detection of spikes in electroencephalogram is currently a prominent area of research, with significant implications for epilepsy diagnosis. There are primarily two types of existing detection methods: signal analysis and machine learning. The former is sensitive to outliers, while the robustness of the latter's algorithms to different data has not been fully verified. Additionally, traditional spike detection methods based on single-channel EEG are susceptible to artifact interference. In response to the limitations of existing algorithms and considering the electrophysiological characteristics of spikes, we propose a spike detection algorithm based on multi-channel data weight fusion and wavelet decomposition. Firstly, a multi-channel weight fusion method is designed using amplitude and waveform trends as feature values to enhance single-channel data according to the discharge characteristics of epileptic spikes. Secondly, the algorithm introduces wavelet decomposition to effectively extract local features from the signal and enhance its ability to detect signals with mutation characteristics. Finally, clinical EEG data collected from epileptic patients verify that the algorithm can achieve accurate detection of interictal spikes at a diagnostic accuracy rate exceeding 92.3%. Compared with traditional single-channel EEG spike detection methods, this approach offers advantages such as high accuracy and simple calculation, making it an effective technology for interictal spike detection in epilepsy.

Keywords: EEG; multi-channel weight fusion; wavelet decomposition; modal maxima; spike wave detection

收稿日期: 2024-03-11 Received Date: 2024-03-11
*基金项目:2022 产业技术基础公共服务平台项目(2022-189-181)、中国科学院学部前沿交叉研判研究(XK2023XXC002)资助项目

0　引　言

癫痫是一种慢性脑部疾病,该疾病的发生是由于大脑神经元的异常放电,使中枢神经系统处于失衡状态,以致患者出现不自主地运动,意识丧失等症状,轻则影响日常生活,重则对生命造成严重威胁[1]。据世界卫生组织报告显示,全球大约有 5 000 万人患有癫痫,这使得它很可能成为全球神经系统疾病[2],与普通人群相比,癫痫患者的过早死亡风险要高出 3 倍。脑电图(electroencephalogram,EEG)是一种不需要通过侵入大脑内部就能获取大脑信息的信号收集技术,并具有极高的时间和空间分辨率。大量研究数据表明,在非癫痫发作期间仍存在神经细胞异常放电现象的癫痫病患者比例为总癫痫病患者的 80%,该现象在 EEG 中的波形表现形式有棘波、尖波、棘慢和尖慢复合波等。临床上医生通常采用提取癫痫发作时的棘波和波尖,同时定量分析相关的病理信息。虽然棘波和尖波的定义在临床上存在差异,但在二者的自动识别领域,它们被同一称为癫痫瞬变现象或棘波。因此,下文将棘波作为棘波和尖波的统称。在当前临床医学上中,检测棘波的“金标准”仍是肉眼目测和人工标记,但这大量的繁琐冗杂任务给相关工作人员带来了巨大的工作压力,因此实现 EEG 癫痫棘波自动化检测意义重大。

针对癫痫棘波的电生理特性,研究人员从形态学[3]、信号相关性[4]、子带分解[5]以及特征工程相关[6]等方面提出了癫痫棘波检测方法。上述方法大致可以分为两类,一类用信号分析的方法从时频域等角度直接对脑电进行分析,目标在于确定相关能够明显区分信号特点的参数,从而实现预测。例如,刘光达等[7]提出了基于小波变换和模极大值法的棘波检测方法,对癫痫发作期间的棘波取得了较好的检测结果。但是该方法需要对棘波嫌疑点进行空间曲面拟合,计算复杂度较高,且未在信号不明显的癫痫发作间期进行分析。文献[8]提到了一种奇异值分解结合差异测度方法,通过矩阵的奇异值分解方法得到脑电信号的时频分布图,然后利用时频分布的差异测度方法达到对棘波的检测目的,其正确率达到 90% 以上,但是误检率相对较高。文献[9]介绍了一种经验模态分解方法来处理癫痫脑电信号,通过得到第一个分解信号后,再提取其非线性能量算子特征,根据该特征值设置阈值,实现癫痫棘波检测,该方法能够提取棘波的明显特征,但是仍会受到非棘波波形数据的干扰。另一类是机器学习分类算法,Jiang 等[10]提出了一种包括多通道尖峰候选样本筛选、数据加权融合、时间序列特征提取和长短时记忆神经网络在内的癫痫棘波检测方法。该方法的检测准确率高,但是无法确定具体放电通道。Anh-Dao 等[11]提出了一种复合棘波检测模型,其中包括数据预处理和特征提取等 4 个部分,再运用人工神经网络进行分类。实验结果表明,该系统能够有效地检测癫痫棘波,但是由于受到与真实癫痫棘波非常相似的伪迹的干扰,该方法还存在一定的误检率。两类方法侧重不同,它们各有优点和局限性。基于信号分析的方法不依赖于大量标记的训练数据,实施相对简单,且易于理解和解释。但在计算速度上有着明显的劣势,同时对来自电极噪声、运动伪迹等的干扰比较敏感,易导致较高的假阳性率;基于机器学习的方法虽然在特定的数据集上可以取得较好的检测结果并且在计算速度上有着一定的优势,但是特征提取和分类算法计算复杂度高,没有统一的分类模型可应用于所有数据集。以及数据集的局限性,从而导致无法充分验证算法的鲁棒性和稳定性。因此,目前临床实践中仍未出现一种自动化棘波检测技术大规模替代人工视觉检测。

基于以上问题,提出了基于多通道权重融合和小波分解的癫痫棘波检测算法。该算法首先利用一种基于癫痫棘波电生理特征进行加权的策略,从而融合多通道数据,再对得到的样本进行小波分解并利用其中的模极大值定位棘波位置,不仅实现了发作间期棘波的精确检测,同时降低了计算成本。与现有方法相比,提出的棘波检测算法对伪迹干扰具有鲁棒性,能够有效利用多通道 EEG 信息进行棘波检测,同时能够降低数据规模。

1　算法原理

癫痫棘波检测算法全流程如图 1 所示,首先使用基于 MATLAB 的 EEGLAB 工具包进行包括去除伪影等步骤的数据预处理,并采用基于幅值和波形权重的特征融合进行棘波数据强化,最后对数据进行小波分解并使用模极大值检测棘波。

1.1　多通道数据加权融合

对多通道数据进行权重融合的目的在于尽可能包含各通道中棘波的有效信息,同时尽可能忽略特征不明显的模糊信号,在加强棘波信号特征的同时,又能降低数据维度,减少计算量,在保证获取多通道数据信息的同时减少计算时间。

棘波波形通常表现为多样性,如图 2 所示。棘波波形趋势的差异性是由复杂的病理生理因素导致的,如患者的年龄和脑部情况等。但是通过观察大量的棘波波形数据后,仍能总结出几种固定形式的棘波波形。

从以上分析可以看出,一组不同波形趋势的标准数据集比单个标准数据更能准确地反映波形趋势。为了确定常见的波形趋势以便进一步分析,本方法通过医学专家标记的癫痫棘波数据集中选取了 8 个在一定程度上能

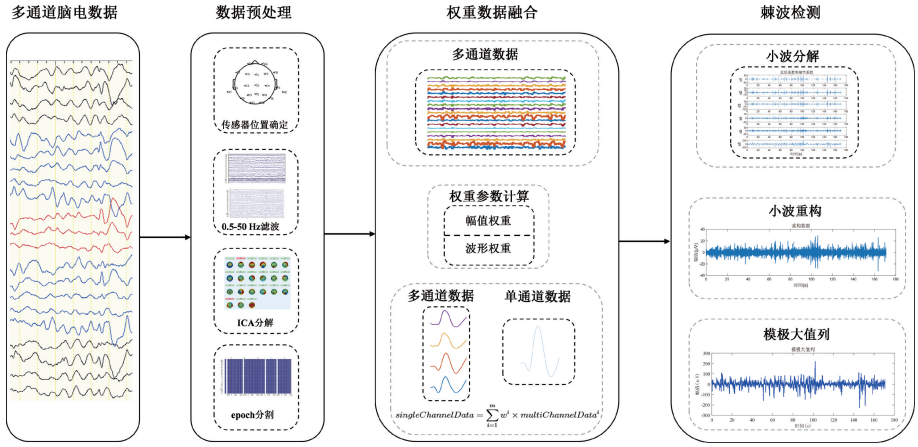

图 1 棘波检测算法流程图

Fig. 1 The flow chart of spike detection algorithm

反映棘波放电波形一般趋势的棘波波形作为模板，如图 3 所示。

图 2 常见的棘波波形

Fig. 2 Common spike wave shape

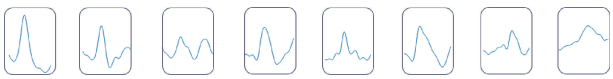

图 3 振幅未归一化的棘波波形

Fig. 3 Spike wave shape with unnormalized amplitude

经过对所选棘波波形数据的全面分析，可以发现波形的幅值大小会对样本波形趋势产生影响，从而影响标准棘波模板数据集的选取。因此，在进行数据处理前，需要先对所选数据进行振幅归一化操作。如图 4 所示，振幅归一化处理后，可以有效避免幅值大小对样本波形趋势的基本标准造成影响，确保选取出的标准棘波模板数据集的准确性和可靠性。

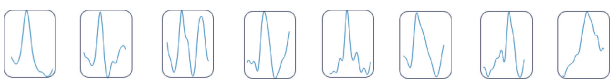

图 4 振幅归一化后的棘波波形

Fig. 4 The shape of the spike wave after amplitude normalization

通过对比图 3 和 4 棘波波形趋势，可以比较出振幅归一化的数据更加能够有效地反映波形趋势的变化，因此，选择振幅归一化的数据作为棘波波形的标准模板。在实际应用中，也可以通过选择不同的归一化方法来确保数据的准确性和可靠性。

而就多通道数据而言，棘波放电多呈现为局灶性，即神经元电信号传导方式是汇聚在中心，并向四周辐射，如图 5 所示。这种放电现象可以从棘波电生理基础和 EEG 检测原理得到解释。癫痫棘波是大脑深处的细胞异常放电引起的，电信号从大脑深处产生并向四周辐射，在辐射过程中由于传导距离不一致以及传感器放置深度不一致，从而产生了不同通道检测到的信号不一致现象，距离放电中心更近的传感器检测到的棘波信号越强，也就是振幅越大。多通道数据权重融合方法就是利用了棘波放电的分布特性，通过多通道数据融合能够有效的强化棘波放电信息，同时降低低振幅数据对样本的干扰，从而进一步提升算法检测精度，并且降低了检测数据维度，加快了计算速度。

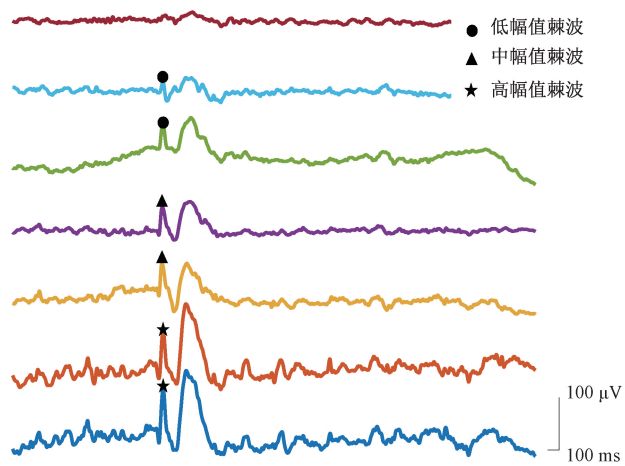

图 5 棘波多通道分布特性

Fig. 5 Spike multi-channel distribution characteristics

根据棘波产生的电生理基础可知，振幅和波形是可以用来描述棘波数据的两大特征。因此，本节将从这两个角度进行深入分析，并对各个通道的样本数据与棘波

数据之间的关联性进行详细描述。振幅方面,通常用于表征电极检测到的电流力度大小,高振幅通常会伴随着放电源的放电强度较高或检测电极与放电源的距离相对较近,从而增大棘波产生的可能性;波形方面,通常用于表征通道数据的波动趋势,若样本波形与标准棘波的相似度越高,则说明样本数据具有更高的棘波数据概率。基于解耦振幅和波形之间的强相关性,统一采用振幅归一化后的数据进行比对和分析。

下文将给出用于多通道数据加权融合所需的振幅和波形的定义。采用较为简便的方法定义振幅特征量,首先通过寻找脑电数据中的极大值点,再定位各极大值相邻的两个极小值点,极大值点到相邻两个极小值点连线间的垂直距离即为棘波振幅。权重计算中的振幅特征定义,如式(1)所示。

$$amp_feature = e^{-\frac{(amplitude-\mu)^2}{2\sigma^2}} \tag{1}$$

式中:*amplitude* 为样本所含波形的振幅。通过使用高斯函数将波形的振幅数据进一步映射至[0,1]区间内,并将其定义为幅值特征量。

由于每种特征值量纲不同,因此先进行统一标准,对特征量进行均值归一化,均值归一化的结果即为各通道振幅权重 w_{amp}^{m},如式(2)所示。

$$w_{amp}^{m} = \frac{amp_feature^{m}}{\sum_{i=1}^{n} amp_feature^{i}} \tag{2}$$

其中,i 表示通道编号,$amp_feature^{i}$ 为振幅特征量,n 为总通道数量。

波形特征量定义如式(3)所示。

$$wave_feature = \lambda e^{-\lambda(shape-shape_{min})} \tag{3}$$

其中,*shape* 表示为振幅归一化之后的样本数据,与标准棘波模板内所有样本数据的最小欧式距离,$shape_{\min}$ 为不同样本数据的 *shape* 中的最小值。*shape* 通过指数函数进一步映射后的数据作为波形特征量。再将波形特征量进行均值归一化,将其结果记为各通道波形权重 w_{shape}^{m},如式(4)所示。

$$w_{shape}^{m} = \frac{wave_feature^{m}}{\sum_{i=1}^{n} wave_feature^{i}} \tag{4}$$

其中,$wave_feature^{i}$ 代表第 i 个通道所对应的波形特征量,n 为棘波候选样本的通道数量。

最终多通道数据融合的权重值就是由幅值和波形权重共同决定的,其计算公式如式(5)所示。然后每一通道的数据样本 *multiChannelData* 在根据式(5)计算出的融合权重值进行融合,从而得到包含多通道数据信息的单通道棘波强化数据样本 *singleChannelData*,其计算过程如式(6)所示。

$$w^{m} = \frac{w_{amp}^{m} \times w_{shape}^{m}}{\sum_{i=1}^{n} w_{amp}^{i} \times w_{shape}^{i}} \tag{5}$$

$$singleChannelData = \sum_{i=1}^{m} w^{i} \times multiChannelData^{i} \tag{6}$$

采用样本筛选并对棘波样本和非棘波样本的振幅和波形特征量进行了分析,如图 6 所示,对比左右两图可以明显看出幅值和波形特征均能够区分棘波和非棘波样本,因此可以将其作为评估通道数据与棘波相关性的量化指标。

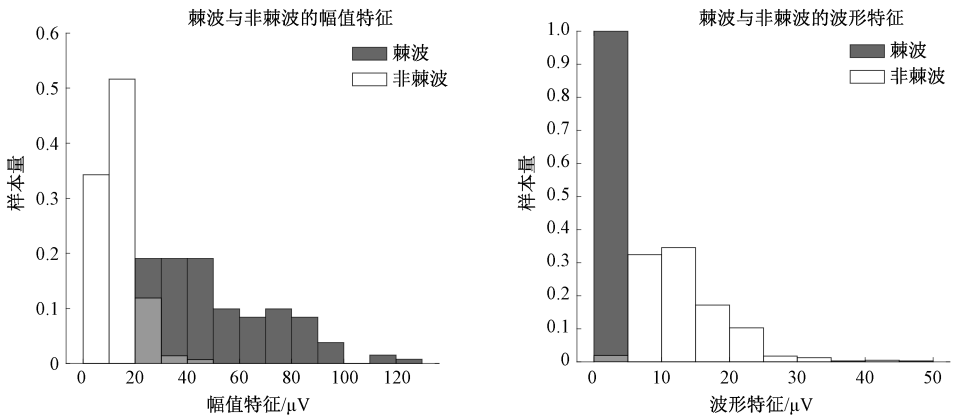

(a) 权重融合前棘波与非棘波样本幅值特征
(a)Amplitude characteristics of spiked and non-spiked samples before weight fusion

(b) 权重融合前棘波与非棘波样本波形特征
(b)Waveform features of both spiked and non-spiked samples before weight fusion

图 6　权重融合前棘波与非棘波样本特征量分布图

Fig. 6　Distribution of characteristic quantities of spiked and non-spiked samples before weight fusion

另外,为了确保权重融合后的数据仍包含棘波相关信息,进一步展示了加权融合后数据的棘波与非棘波样本的振幅与波形特征量的分布图,如图 7 所示。可以看出数据融合后两类特征对棘波与非棘波的区分程度较之前有了明显提升。

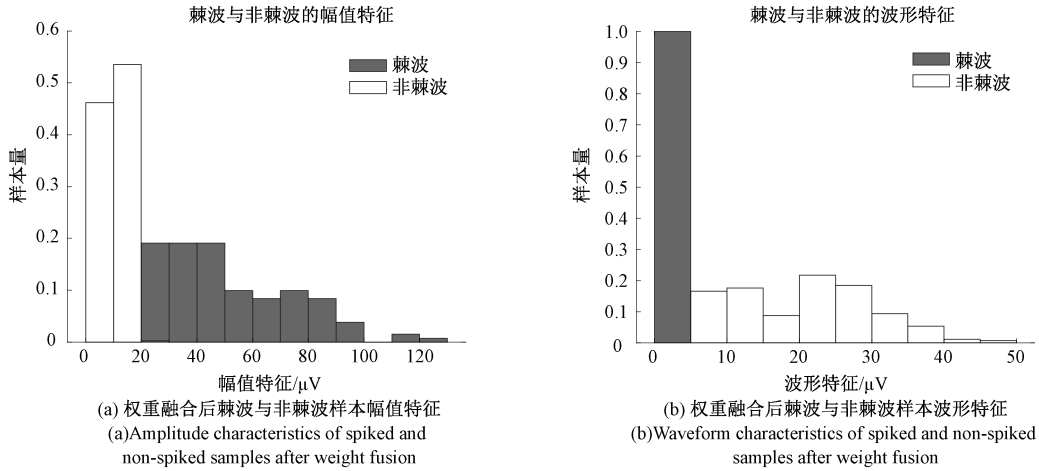

(a) 权重融合后棘波与非棘波样本幅值特征
(a)Amplitude characteristics of spiked and non-spiked samples after weight fusion

(b) 权重融合后棘波与非棘波样本波形特征
(b)Waveform characteristics of spiked and non-spiked samples after weight fusion

图 7 权重融合后棘波与非棘波样本特征量分布图

Fig. 7 The distribution of characteristic quantities of spiked and non-spiked samples after weight fusion

图 8 简要地展示了多通道数据融合为单通道数据的过程,先获取多个 0.4 s 时间窗数据作为代融合数据,再进行权重计算,最后通过计算所得权重值融合得到单通道数据,过程如图 8 所示。

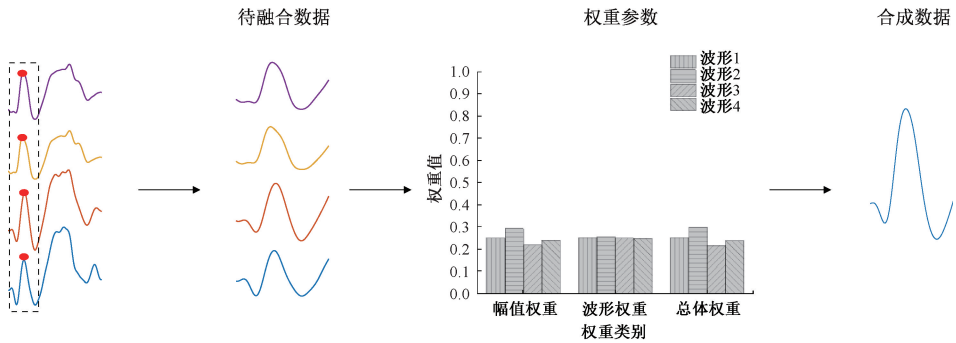

图 8 多通道数据融合为单通道数据过程图

Fig. 8 Multi-channel data is fused into single-channel data process diagram

1.2 基于小波分解的棘波检测

小波变换[12]是一种具有时频优越性的信号分析方法,它能够提供包含时间和空间的二维信息,在处理时变信号时具有极大的优势。小波分解是小波变换过程之一,它的重点在于将信号分解成不同尺度和频率的数据。这个过程通过层次化的递归操作,将信号分解成近似系数和细节系数,使得研究者能够观察到信号在不同尺度下的变化。小波分解在信号处理中常被用于特征提取、数据压缩等应用。Mallat 算法[13]是小波分解的一种层次化、逐层递归的算法。以下是 Mallat 算法的主要步骤和相关数学公式:

步骤 1)初始化:将输入信号表示为一组近似系数和细节系数。这一步通常使用一个小波函数(母小波)和一组尺度参数来进行卷积操作,如式(7)所示。

$$\begin{cases} c_{j,k} = \langle f, \boldsymbol{\phi}_{j,k} \rangle = \int f(t) \cdot \boldsymbol{\phi}_{j,k}(t)\,\mathrm{d}t \\ d_{j,k} = \langle f, \boldsymbol{\varphi}_{j,k} \rangle = \int f(t) \cdot \boldsymbol{\varphi}_{j,k}(t)\,\mathrm{d}t \end{cases} \tag{7}$$

其中,$c_{j,k}$ 是近似系数,$d_{j,k}$ 是细节系数,$\boldsymbol{\phi}_{j,k}$ 和 $\boldsymbol{\varphi}_{j,k}$ 分别是近似和细节小波函数,j 表示尺度,k 表示平移参数。

步骤 2)逐层分解:对近似系数进行进一步的小波分解,得到新的近似系数和细节系数。重复这一步骤直到达到所需的分解层次。如式(8)所示。

$$\begin{cases} c_{j+1,k'} = \langle c_{j,k}, \boldsymbol{\phi} \rangle = \int c_{j,k}(t) \cdot \boldsymbol{\phi}(t - 2^{-j}k')\,\mathrm{d}t \\ d_{j+1,k'} = \langle c_{j,k}, \boldsymbol{\varphi} \rangle = \int c_{j,k}(t) \cdot \boldsymbol{\varphi}(t - 2^{-j}k')\,\mathrm{d}t \end{cases} \tag{8}$$

其中,$c_{j+1,k'}$ 是新的近似系数,$d_{j+1,k'}$ 是新的细节系数,$\boldsymbol{\phi}$ 和 $\boldsymbol{\varphi}$ 分别是小波函数和细节小波函数。

步骤 3)重复步骤 2):对新的近似系数进行进一步的

小波分解,直到达到所需的分解层次。

整个过程是一个逐层递归的过程,通过不断降低尺度,可以获取信号的多尺度表示。最后得到多个信号,再结合所需信号的特性进行相应的信号重构。仅利用小波分解中的部分系数来近似原始信号。这种方法通常称为小波稀疏重构。具体表示,如式(9)所示。

$$f(t) \approx \sum_{j,k} \tilde{c}_{j,k} \cdot \boldsymbol{\phi}_{j,k}(t) + \sum_{j,k} \tilde{d}_{j,k} \cdot \boldsymbol{\varphi}_{j,k}(t) \quad (9)$$

其中, $\tilde{c}_{j,k}$ 和 $\tilde{d}_{j,k}$ 分别为选定的近似系数和细节系数。这种近似提供了对原始信号的一种低维表示,通过选定重要的小波系数,可以在减少数据维度的同时尽可能地保留信号的关键特征。

小波变换具有时频局部化特性,它能表征函数的奇异性[14]。数学上对奇异性的定义是,函数在某处间断或某阶导数不连续,该点也成为奇异点。信号的奇异性能通过 Lipschitz 指数来表征。下面给出描述信号奇异性的一般定义[15]:

设有非负整数 $n \leqslant \alpha \leqslant n+1$,如果存在着两个常数 $C > 0$ 和 $x_0 > 0$ 与一个 n 阶多项式 $P_n(x)$,对于 $x \in (x_0 - \delta, x_0 + \delta)$ 使得 $|f(x_0 + x) - P_n(x)| \leqslant C|x|^{\alpha}$,则称函数 $f(x)$ 在点 x_0 是 Lipschitzα 的。如果函数 $f(x)$ 在点 x_0 上的 Lipschitz 指数 $\alpha < 1$,则称函数在该点是奇异的。

由信号奇异性检测原理[16]可知,当小波函数看作是某一平滑函数的一阶导数或二阶导数时,信号的突变点可分别由小波变换模的局部极值点和小波变换的过零点表示。因此采用这两种方法理论上都可以检测信号的奇异点。但是在实际应用中,前者还能够给出信号变化快慢的信息,因此,用局部极值点进行检测更具有优越性。时变信号 $f(x)$ 的特征在于包含了大量的奇异点,而小波变换的精妙之处在于其对局部细节的捕捉,通过检测小尺度上的小波变换模极大值点,从而有效地检测出时变信号 $f(x)$ 包含地所有奇异点,为后续地分析与处理提供了依据。因此,小波变换为时变信号的奇异点检测提供了一种有效的手段。

脑电信号中的棘波信号具有局部奇异性,也就是说,可通过小波变换模的局部极大值来确定棘波位置。因此,采用小波变换模极大值定位来检测棘波位置。在检测棘波位置的过程中,需要关注小波变换模的局部极大值,这些极大值点能够反映出信号在突变点的奇异性。然而,要精确地定位这些极大值点并非易事,需要综合考虑信号的频率特性以及小波变换的尺度选择。为了提高检测的准确性,可以结合多尺度小波变换的方法,通过在不同尺度下分析信号特性,从而更精准地确定棘波的位置。这样的方法能够有效应对信号复杂性带来的挑战,为棘波信号的检测提供了更可靠的依据。

2　数据采集与处理

本研究使用山东大学齐鲁医院提供的关于癫痫患者头皮脑电静息态的数据,这些数据用于评估棘波检测算法的性能,研究对象的年龄范围是 20~60 岁。脑电图的采集工具是 NIHON KOHDEN 公司生产的 EEG-2100,其采样频率为 500 Hz,电极放置位置按照国际 10~20 的标准严格实施。全部数据选取和棘波数据标注都由山东大学齐鲁医院神经科专家完成。监测脑电图持续时长可达数小时,为了方便后续数据处理,根据医生诊断报告将数据分为 10 段 EEG 数据。

在头皮脑电数据采集过程中,受试者轻微移动、心脏跳动等动作以及环境噪声等都会给数据带来伪迹,从而对棘波检测产生干扰,因此需要对原始的脑电数据进行相应的预处理操作。采用基于 MATLAB 平台的 EEGLAB 工具包对原始脑电信号进行预处理,主要包括传感器位置确定、数据滤波、独立分量分析(independent component analysis, ICA)等流程。为了后续检测棘波出现的区域,实验先根据电极位置信息进行准确定位,传感器位置如图 9 所示。再采用 0.5~50 Hz 的带通滤波器,去除低频漂移和高频噪声。为了进一步去除肌电、眼电等伪迹干扰,利用对脑电信号进行 ICA 分解,采用默认算法 runica 执行。该算法适合分析和总结大脑传导出的头皮脑电信号图,实验最终得到独立成分的头皮分布图,并结合 ICLabel 概率分析是否是伪影成分,如图 10 所示为眼动伪影。由于整段数据的采集时间较长,如果直接进行棘波检测会降低检测效率。因此,保证算法的检测效率以及能够实现对棘波的精确检测,首先对整段脑电数据进行时间窗分割,设计了一个 0.4 s 的脑电数据样本分割时间,0.4 s 的时间窗长度不仅能确保完整地采集一个棘波信号,还能满足后续的慢波波形跟踪需求。该分割时长能够确保棘波放电波形在连续分割下的完整性,因此未设置重叠率。

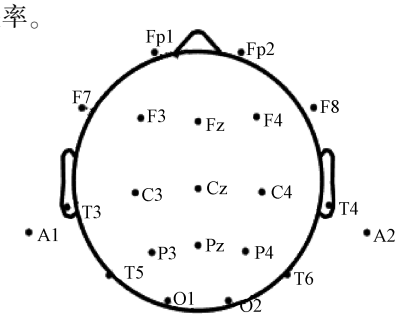

图 9　电极位置确定

Fig. 9　Electrode position determination

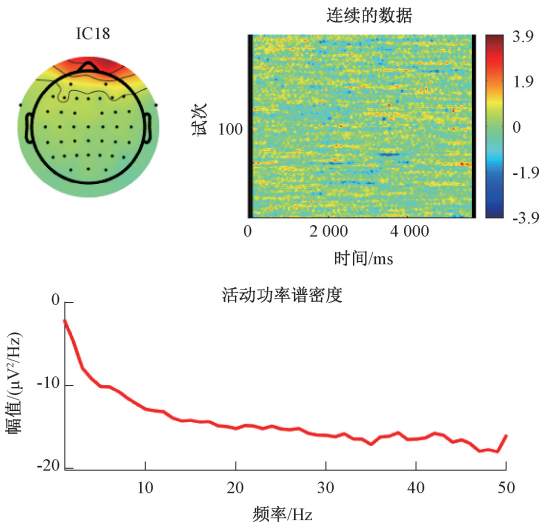

图 10 ICA 分解出的眼动伪影

Fig. 10 Eye movement artifacts decomposed by ICA

对于预处理后的数据,使用上文所提到的多通道权重融合方法,将数据融合为单通道数据。针对单通道数据再使用小波分解,根据癫痫脑电波形特征及所选数据的特性,采用 db4 为小波函数进行 5 层分解[17],小波分解后的近似系数和细节系数及其频谱分别如图 11 和 12 所示。癫痫棘波频率范围在 13.5~50 Hz[18],为能针对棘波检测需求,对小波分解后的系数结合棘波频率特性进行相应信号重构。本方法选择近似系数 d3、d4、d5 进行小波重构。

计算重构信号的模极大值列,如图 13 所示。再设置阈值,以模极大值幅值前 1%为分界线,确定棘波所在位置。

3 结果与讨论

3.1 评估指标

该方法采用检测率(sensitivity, Sens)和误检率(false positive rate, FPR)对该算法进行综合评估,两类性能指标的表达式如式(10)所示。

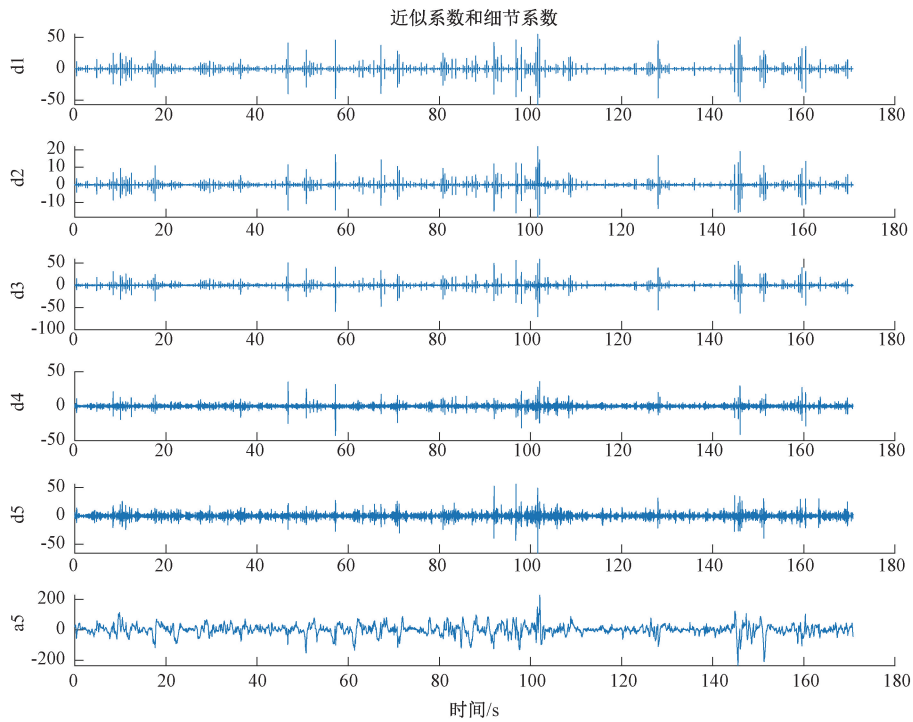

图 11 小波变换后的近似系数和细节系数

Fig. 11 The approximate coefficients and detail coefficients after wavelet decomposition

$$Sens = \frac{TP}{TP + FN}, FPR = \frac{FP}{FP + TN} \tag{10}$$

其中,相关参数来自混淆矩阵[19],如表 1 所示。

其中,真正例表示实际为正例,模型也正确地预测为正例。假正例表示实际为负例,模型错误地将其预测为正例。真负例表示实际为负例,模型正确地预测为负例。假负例表示实际为正例,模型错误地将其预测为负例。

表 1 混淆矩阵

Table 1 Confusion matrix

真实值	预测值	
	正例	反例
正例	真阳例(true positive,TP)	假阴例(false negative,FN)
反例	假阳例(false positive,FP)	真阴例(true negative,TN)

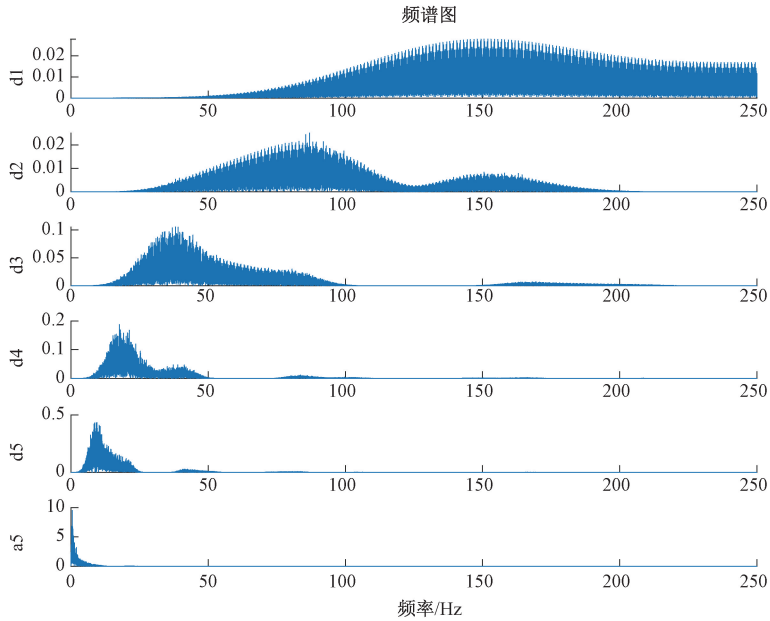

图 12　小波分解后的近似系数和细节系数的频谱图

Fig. 12　Spectral diagram of approximate coefficients and detail coefficients after wavelet decomposition

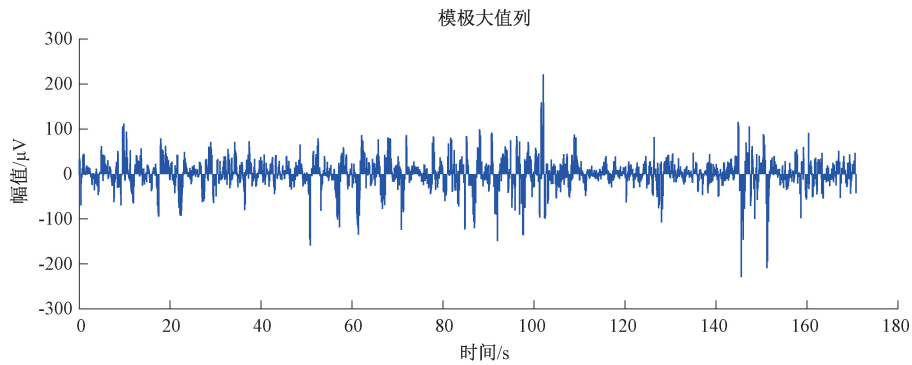

图 13　小波分解的模极大值列

Fig. 13　Modulus maximum column of wavelet decomposition

给出了两种评价指标:检测率代表了算法检测出的棘波样本中与专家标记一致的部分占专家标记的所有棘波样本的比例,这显示了该模型对棘波的识别能力;而误检率则是算法检测出的棘波样本中与专家标记不一致的部分占专家标记的所有非棘波样本的比例,这体现了模型对干扰的抵抗能力。

3.2　实验结果与分析

运用上述方法分析了山东大学齐鲁医院癫痫患者的头皮脑电数据,部分棘波检测效果如图 14 所示。图 14 中的合成数据即为基于多通道权重融合后的单通道数据。由图中可以清晰地观测到,由医院专家标记出来的棘波位置,均被该检测方法检测自动标记得出,说明此检测方法有着很高的检测精确度。同时,该检测方法自动标记出的棘波,并未全部被专家标记出来,说明该检测方法存在一定误差,但总体来说该方法有较优异的检测效果。

本实验所用数据使用滑动窗口进行分割,单个窗口长度为 0.4 s,总共包含 3 174 400 个癫痫数据样本。表 2 为本算法的棘波检测结果,算法的平均检出率为 92.31%,平均误检率为 0.02%。由此可见,该算法展现出较高的检出率,且误检率相对较低。其中误检率主要来源于波形及幅值都与棘波较为相似的波形干扰。

此外,本研究还对 10 组数据的检出率进行 t 检验[20],得到该方法获得的检出率为 93±3.59%。同时,以 Thanaraj[21] 所提方法得到的检出率为总体均值,得到 $p>0.05$,说明所述方法与其方法得到的结果不存在显著差异。t 检验结果进一步说明了此方法的有效性。

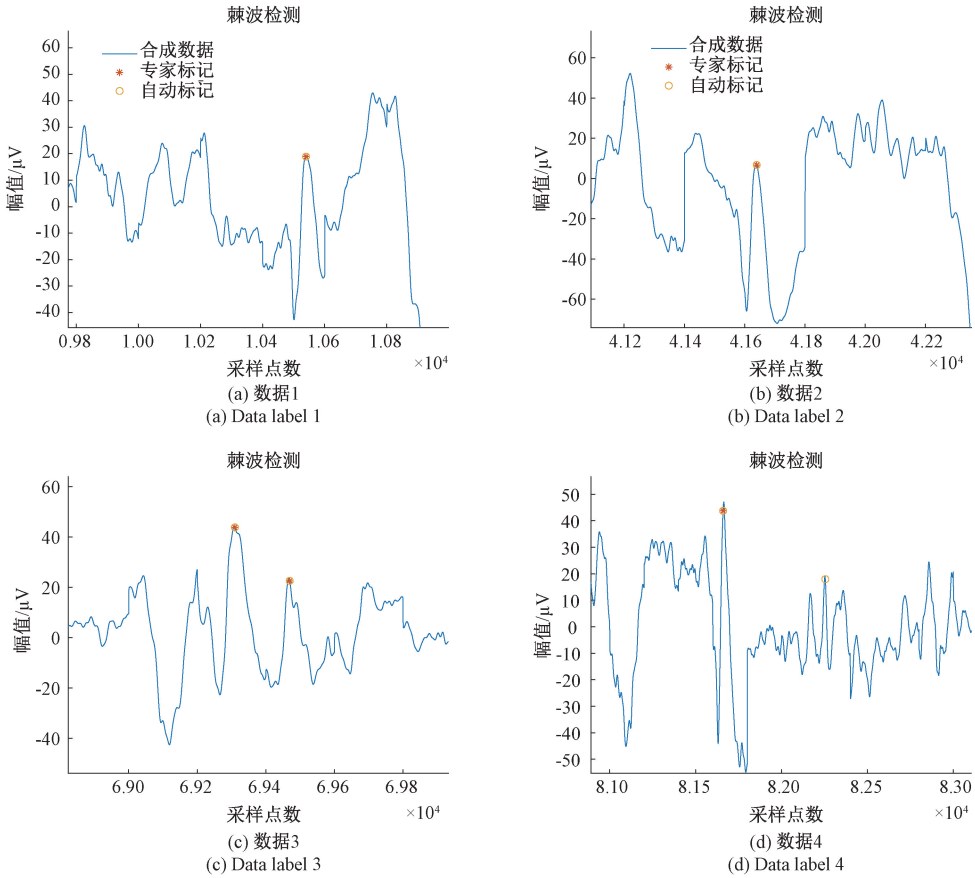

图 14 棘波检测效果

Fig. 14 Spike detection effect

表 2 棘波检测结果

Table 2 Spike test results

数据标号	棘波数	检出率/%	误检率/%
数据 1	4	75	0. 08
数据 2	3	100	0. 08
数据 3	3	100	0. 09
数据 4	3	100	0. 09
数据 5	4	100	0. 02
数据 6	3	100	0. 01
数据 7	4	75	0. 02
数据 8	5	100	0. 05
数据 9	5	100	0. 05
数据 10	5	80	0. 03

综上所述,基于多通道权重融合和小波分解的棘波检测方法有着较好的应用前景。

4 结 论

棘波是癫痫诊断和治疗评估中的重要生物标志物。针对棘波检测问题,提出一种多通道脑电加权融合与小波分解相结合的棘波算法。该算法首先使用基于 MATLAB 的 EEGLAB 工具包进行包括去除伪影等步骤的数据预处理,并采用基于权重的特征融合进行棘波数据强化,最后对数据进行小波分解并使用模极大值检测棘波。该算法在临床癫痫头皮脑电数据取得了较好的检测结果,因此方法具有良好的应用前景。

棘波放电现象广泛存在于各癫痫患者的脑电活动中,并且癫痫疾病又可进行进一步细分为多种病症。因此,未来可以通过扩充数据集,进一步研究该方法在多种癫痫疾病中的棘波检测效果。另外,癫痫灶的定位及癫痫发作的预测对于医生进行癫痫诊断及治疗至关重要,因此也是未来值得研究的工作。

参考文献

[1] 韦博轩, 张冀聪. EEG 及 MEG 痫样棘波检测算法研究现状[J]. 中国医疗设备, 2019, 34(11): 30-33.
WEI B X, ZHANG J C. Research status of epileptic spike detection algorithms based on EEG and MEG[J]. China Medical Devices, 2019, 34(11): 30-33.

[2] EIN S A A, DESSOUKY M M, EL-SAYED A, et al. EEG seizure detection: Concepts, techniques,

challenges, and future trends[J]. Multimedia Tools and Applications, 2023, 82(27): 1-31.

[3] 马东华, 郑旭媛, 王真. 基于形态成分分析的癫痫脑电棘波检测[J]. 生物医学工程学杂志, 2013, 30(4): 710-713,723.
MA D H, ZHENG X Y, WANG ZH. Detection of epileptic spike wave in EEG signals based on morphological component analysis [J]. Journal of Biomedical Engineering, 2013, 30(4): 710-713,723.

[4] KARACOR D, NAZLIBILEK S, SAZLI M H, et al. Discrete lissajous figures and applications [J]. IEEE Transactions on Instrumentation and Measurement, 2014, 63(12): 2963-2972.

[5] LUCA M. A neural algorithm for the non-uniform and adaptive sampling of biomedical data[J]. Computer in Biology Medicine, 2016, 71: 223-230.

[6] AZAMI H, SANEI S. Spike detection approaches for noisy neuronal data: Assessment and comparison [J]. Neurocomputing, 2014, 133: 491-506.

[7] 刘光达, 王依萌, 胡秋月, 等. 基于小波变换和模极大值法的癫痫发作检测与分析[J]. 测控技术与仪器仪表, 2019, 45(4): 74-77.
LIU G D, WANG Y M, HU Q Y, et al. Detection and analysis of epileptic seizure based on wavelet transform and modulus maximum approach[J]. Measurement and Control Technology and Instruments, 2019, 45(4): 74-77.

[8] 彭睿旻, 江军, 匡光涛, 等. 基于 EEG 的癫痫自动检测:综述与展望[J]. 自动化学报, 2022, 48(2): 335-350.
PENG R M, JIANG J, KUANG G T, et al. EEG-based automatic epilepsy detection: Review and outlook[J]. Acta Automatica Sinica, 2022, 48(2): 335-350.

[9] 杜轻, 辛守庭, 雷新宇, 等. 基于脑网络和 TSK 模糊系统的癫痫脑电识别[J]. 计算机工程与应用, 2020, 56(2): 133-140.
DU Q, XIN S T, LEI X Y, et al. Seizure identification from EEG signals based on functional brain network and TSK fuzzy system [J]. Computer Engineering and Applications, 2020, 56(2): 133-140.

[10] JIANG T, XU Z, CAO J, et al. BECT spike detection based on novel multichannel data weighted fusion algorithm [J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2022, 69(11): 4613-4617.

[11] ANH-DAO N T, LINH-TRUNG N, NGUYEN L V, et al. A multistage system for automatic detection of epileptic spikes[J]. REV Journal on Electronics and Communications, 2018, 8(1-2): 1-13.

[12] 杨瑞, 李维勤, 白清, 等. CEEMDAN-WT 降噪提升 BOTDA 信噪比研究[J]. 电子测量与仪器学报, 2022, 36(12): 28-36.
YANG R, LI W Q, BAI Q, et al. Signal-to-noise ratio improvement for BOTDA using CEEMDAN-WT method [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(12): 28-36.

[13] 吴红卫, 李铎, 顾思洪. 小波滤波在时间同步系统中应用研究[J]. 仪器仪表学报, 2019, 40(2): 182-189.
WU H W, LI D, GU S H. Application research of wavelet filtering in time synchronization system [J]. Chinese Journal of Scientific Instrument, 2019, 40(2): 182-189.

[14] 廖里程, 梅劲松, 赵阳. 机车车轮踏面擦伤数据处理算法的研究[J]. 电子测量技术, 2015, 38(5): 114-118.
LIAO L C, MEI J S, ZHAO Y. Research on locomotive wheel tread irregularities data processing algorithm [J]. Electronic Measurement Technology, 2015, 38(5): 114-118.

[15] 李文浩, 余波, 胡锦蘅. 基于小波奇异性变换理论的离心泵空化分析[J]. 黑龙江大学工程学报, 2015, 6(4): 78-82.
LI W H, YU B, HU J H. Analysisof centrifugal pump cavitation basedon wavelet singularity transformation theory [J]. Journal of Heilongjiang Hydraulic Engineering College, 2015, 6(4): 78-82.

[16] 周封, 朱瑞, 王晨光, 等. 一种配电网高阻接地故障在线监测与辨识方法[J]. 仪器仪表学报, 2015, 36(3): 685-693.
ZHOU F, ZHU R, WANG CH G. Online criterion and identification of single-phase ground fault with high resistence in distribution network[J]. Chinese Journal of Scientific Instrument, 2015, 36(3): 685-693.

[17] 辛元明, 谭峰, 田芳明. 基于小波变换的植物电信号降噪方法研究[J]. 电子测量与仪器学报, 2019, 33(12): 190-196.
XIN Y M, TAN F, TIAN F M. Research on denoising method of plant electrical signal based on wavelet transform[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(12): 190-196.

[18] 袁莎莎. 癫痫发作自动检测算法研究[D]. 济南: 山东大学, 2016.
YUAN SH SH. Research on automatic detection algorithm

of epileptic seizure [D]. Jinan: Shandong University, 2016.

[19] 李丹, 王慢慢, 刘俊德, 等. 基于轻量级卷积神经网络的带钢表面缺陷识别[J]. 仪器仪表学报, 2022, 43(3): 240-248.
LI D, WANG M M, LIU J D, et al. Steel surface defect recognition based on a lightweight convolutional neural network[J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 240-248.

[20] GUO B B, YUAN Y. A comparative review of methods for comparing means using partially paired data[J]. Statistical Methodsin Medical Research, 2017, 26(3): 1323-1340.

[21] THANARAJ P, PARVATHAVARTHINI B. Multichannel interictal spike activity detection using time-frequency entropy measure[J]. Australasian Physical& Engineering Sciencesin Medicine, 2017, 40(2): 413-425.

作者简介

俞小彤,2021 年于中国计量大学获得学士学位,2024 年于北京航空航天大学获得硕士学位,主要研究方向为脑信号处理。
E-mail: xiaotongyu1998@163.com

Yu Xiaotong received her B. Sc. degree from China Jiliang Universityin 2021, M. Sc. degree from BeihangUniversity in 2024. Her main research interest includes brain signal processing.

赵若辰,2021 年于南京航空航天大学获得硕士学位,目前于北京航空航天大学攻读博士学位,主要研究方向为脑磁图信号处理和分析。
E-mail: zhaoruochen@buaa.edu.cn

Zhao Ruochen received the B. Sc. degree in Nanjing University of Aeronautics and Astronautics in 2021. Now he is a Ph. D. candidate with the Beihang University, Beijing, China. His main research interests include MEG signals processing and analysis.

宁晓琳(通信作者),2001 年毕业于山东师范大学计算机专业,2007 年博士毕业于北京航空航天大学,现为北京航空航天大学仪器科学与光电工程学院教授,主要研究方向为脑磁图信号处理、多模态生物医学成像技术和统计信号处理。
E-mail:ningxiaolin@buaa.edu.cn

Ning Xiaolin (Corresponding author) received her B. Sc. degree in computer science from Shandong Normal Universityin 2001, and Ph. D. degree in mechanical engineering from Beihang Universityin 2007. She has been a professor with the School of Instrument and Optoelectronic Engineering, Beihang University. Her main research interests include MEG signal processing, multimodality biomedical imaging techniques and statistical signal processing.