

DOI: 10.13382/j.jemi.B2306753

个体化频带滑动窗特征的轻度认知障碍诊断研究*

李 昕^{1,2} 屈中杰^{1,2} 李梓澎^{1,2} 尹立勇³ 苏 芮⁴

(1. 燕山大学电气工程学院 秦皇岛 066004; 2. 河北省测量技术与仪器重点实验室 秦皇岛 066004;
3. 河北省秦皇岛市第一医院神经内科 秦皇岛 066004; 4. 河北医科大学医学影像学院 石家庄 050000)

摘 要:轻度认知障碍(MCI)是老年性痴呆诊断的关键阶段,脑电(EEG)信号特征可以反映MCI患者的认知状态,帮助实现早期诊断。现有研究在EEG特征提取过程中,针对脑电各节律,大多采用固定的时间窗完成分段处理,忽略了不同节律的特征差异,从而影响诊断效果。针对该问题,本文提出了一种新的组合滑动窗优化算法,该算法通过迭代振幅调整傅里叶变换(IAAFT)对零模型的构建方法进行了改进,以此得到评估大脑动态特性指标 K_{PLI} ,通过对EEG各频段信号采取多种滑动窗组合,并以 K_{PLI} 指标引导,得到适合不同频段的最佳滑动窗组合。在最佳滑动窗组合基础上,对各频段组合提取相位滞后指数(PLI),进行连续小波变换(CWT)特征,通过ResNet-MLP双通道分类网络实现MCI诊断。结果显示,使用个性化组合频段滑动窗对88名受试者(32名MCI患者,36名阿尔茨海默症患者以及20名正常对照组)实现了诊断分类,得到了82.2%的分类准确率,比固定窗的分类提高了10%(得到了72.2%的分类准确率)。结果表明,基于个体化脑电节律特征组合能够更好提取MCI的特征,提高轻度认知障碍诊断的正确率与特异性,是一种有效的脑电特征提取方法。

关键词: 滑动窗;零模型;连续小波变换;相位滞后指数

中图分类号: TP391.4 **文献标识码:** A **国家标准学科分类代码:** 520.20

Diagnostic study of mild cognitive impairment with individualized frequency band sliding window features

Li Xin^{1,2} Qu Zhongjie^{1,2} Li Zipeng^{1,2} Yin Liyong³ Su Rui⁴

(1. School of Electrical Engineering, Yanshan University, Qinhuangdao 066004, China; 2. Hebei Provincial Key Laboratory of Measurement Technology and Instrumentation, Qinhuangdao 066004, China;
3. Department of Neurology, Qinhuangdao First Hospital, Qinhuangdao 066004, China;
4. School of Medical Imaging, Hebei Medical University, Shijiazhuang 050000, China)

Abstract: Mild cognitive impairment (MCI) is a key stage in the diagnosis of senile dementia, and the characteristics of electrical brain (EEG) signals can reflect the cognitive status of MCI patients and help achieve early diagnosis. In the process of EEG feature extraction, most existing studies use fixed time windows to complete segmentation processing for each rhythm of EEG, ignoring the feature differences of different rhythms, thus affecting the diagnostic effect. In view of this problem, a new combined sliding window optimization algorithm is proposed, which improves the construction method of zero model by iterative amplitude adjustment Fourier transform (IAAFT), so as to evaluate the brain dynamic characteristics K_{PLI} . By adopting a variety of sliding window combinations for EEG frequency band signals and guiding them with K_{PLI} indicators, the best sliding window combinations suitable for different frequency bands are obtained. Based on the best sliding window combination, the phase lag index (PLI) is extracted from each band combination, the continuous wavelet transform (CWT) feature is performed, and the MCI diagnosis is realized through the ResNet-MLP dual-channel classification network. The results show that diagnostic classification was achieved for 88 subjects (32 MCI patients, 36 Alzheimer's disease patients, and 20 healthy control) using a personalized combination band sliding window, and the

收稿日期:2023-07-19 Received Date: 2023-07-19

* 基金项目:河北省自然科学基金(F2022203005, F2019203515)、燕山大学与秦皇岛市第一医院医务人员交叉特色项目(UY202201)、河北省科技计划项目(236Z2004G)、河北省教育厅科学研究项目(QN2024061)资助

classification accuracy was 82.2%, which is 10% higher than the classification of fixed window (72.2% classification accuracy is obtained). The results showed that based on the individualized EEG rhythm feature combination, the features of MCI could be better extracted, and the accuracy and specificity of the diagnosis of mild cognitive impairment could be improved, which was an effective EEG feature extraction method.

Keywords:sliding windows; zero model; continuous wavelet transform; phase lag index

0 引 言

轻度认知障碍 (mild cognitive impairment, MCI) 是介于正常老化与痴呆之间的过渡阶段^[1-2]。早期诊断有助于提高患者的生活质量,并激励他们积极参与治疗计划。脑电图 (electroencephalogram, EEG) 作为一种非侵入式的方法,可以实时的获取大脑活动产生的神经生理电信信息^[3],并且具有高分辨率,无法掩饰和无法改变的特点^[4-5],因此是一种广泛使用的诊断工具。

由于 EEG 信号量庞大,为了能够更好的分析其潜在特征,大多都会将信号进行分段处理。Jonathan 等^[6]通过将信号分割成 2 s 的时间段,构造了动态高低阶网络用来分析驾驶的疲劳程度, Lian 等^[7]将信号分割成 2 s 的非重叠段并进行重新参考,最终用于后续的微状态分析。赵亮等^[8]对 EEG 信号进行了矩形窗分段处理,滑动窗长为 20 s,滑动步长为 2 s,将结果用于最终的分类识别。同样, Yun 等^[9]为了提高计算信号变异性的准确度,每 2 s 对 EEG 信号进行一次检测。Tian 等^[10]采用两种窗口长度 (2 和 8 s) 的非重叠矩形窗口来分割 EEG 信号,进而提取到不同的脑电图状态。Roy^[11]将 EEG 信号分割成 1 s 的时间窗长度,用以获得空间特征。他们均是对不同频段的信号采取了相同的滑动窗类型进行的分段处理,并未考虑不同频段信号之间的特异性。

本文通过对 EEG 信号各频段进行不同滑动窗和重叠率组合的分段处理,采取特定指标对分段效果进行评估,得出适合各个频段的滑动窗和重叠率组合。并对经过分段处理后的数据分别提取其相位滞后指数特征以及进行连续小波变换处理并从处理后的数据中提取均值、标准差、偏度、峰度、模糊熵特征,将提取到的特征使用 ResNet-MLP 双通道分类模型进行三分类,将其与整体统一分段处理的结果进行对比,实验结果发现,使用不同分段组合处理的分类准确率要高于统一分段处理,表明对不同频段采用不同分段处理有助于进一步提高 MCI 和 AD 患者的识别率。

1 EEG 数据采集

本次实验共有 88 名受试者参与,分别为 20 名正常人 (healthy control, HC), 32 名 MCI 患者和 36 名阿尔茨海

默症患者 (Alzheimer's disease, AD)。本次采集系统共有 16 个电极 (FP1, FP2, F3, F4, C3, C4, P3, P4, O1, O2, F7, F8, T3, T4, T5, T6), 如图 1 所示,电极位置参考的是国际 10~20 标准导联系统,采集频率为 1 000 Hz,每名受试者共采集了 6 min 的 EEG 信号,并剔除了第 1 min 内的信号,共保留了 5 min 的信号 (总计 EEG 信号数据长度为 300 000)。所有参与者都使用简易心理状态测试、蒙特利尔认知评估和日常生活测试,并且均以书面形式向河北省秦皇岛市第一医院神经内科医生提供知情同意书。这项实验得到了河北省秦皇岛市第一医院伦理审查委员会的批准。实验前向所有参与者解释了采集数据的目的和研究意义。




图 1 16 通道电极分布
Fig. 1 16-channel electrode distribution

首先通过零相移滤波器对 EEG 信号进行滤波,保留 0.1~49 Hz 部分。独立成分分析 (independent component analysis, ICA) 是一种由盲信号源分解技术发展而来的多通道信号处理方法,ICA 将多通道的 EEG 信号按统计独立的原则分解成若干相互独立的部分,来进一步实现信号的增强和分析。在本次研究中,选择使用信息极大值原理进行 ICA 处理,利用 ICA 将 EEG 信号分解为 16 个组成成分,通过观察各组成成分的能量分布地形图以及功率谱密度,并以此为依据判断组成成分中是否存在噪声,噪声类型主要有水平和垂直眼电伪迹以及因头动和身体扭动引起的干扰。当存在噪声时,选择剔除相应的组成成分。

对预处理后的 EEG 信号通过带通滤波器分成 5 个频段,分别为 δ 频段(1~4 Hz)、 θ 频段(4~8 Hz)、 α 频段(8~16 Hz)、 β 频段(16~30 Hz)、 γ 频段(30~49 Hz)。

2 基于改进零模型的滑动窗

2.1 滑动窗设计与评估参数

滑动窗口步长和重叠率的设计影响了 HC 组, MCI 组和 AD 组之间的差异。适当的窗口大小和补偿的设计有利于进一步发现各组之间的差异^[12]。因此,需要确定合适的滑动窗方案以及对滑动窗效果进行评估的指标。

步骤 1) EEG 信号的采样频率为 1 000 Hz。首先选取 1 000~4 000 个数据点(1~4 s)作为窗口长度,窗口之间的重叠程度设计为窗口长度的 0%、25%、50%、75%。最后得到 20 个不同的滑动窗口设计。

步骤 2) 对窗口数据求取其相位滞后指数 (phase lag index, PLI) 矩阵, 并利用式 (1) 求取 k_{real} 计算所需的序列 R :

$$r_i = \frac{1}{N-1} \sum_{j=1, j \neq i}^{N-1} \frac{\sum_{t=1}^n A_{i,j}(t) A_{i,j}(t+1)}{\sqrt{A_{i,j}(t) A_{i,j}(t+1)}} \quad (1)$$

其中, r_i 为序列 R 的第 i 个元素, N 为每种滑动窗口方案下时间序列的分段数, j 是与 i 不同的节点, n 是网络的总节点数。 $A_{i,j}(t)$ 是在第 t 段时间窗的 PLI 矩阵的第 i 行, 第 j 列的值。而 k_{real} 即为所得序列 R 的标准差:

$$k_{real} = \sqrt{\frac{1}{n} \sum_{i=1}^n (r_i - \bar{R})^2} \quad (2)$$

其中, k_{real} 用来描述脑功能网络动态变化过程中的波动程度。

步骤 3) 为了判断设计的滑动窗口的动态特性, 分别分析了由 EEG 构建的动态网络的时间变化行和相应的零模型。动态性能的评价指标由其比率 K_{PLI} 表示。 K_{PLI} 的值越大, 动态特性就越强。反之, K_{PLI} 的值越小, 动态特性就越弱。

$$K_{PLI} = \frac{k_{real}}{\frac{1}{N} \sum_{i=1}^N k_{random}(i)} \quad (3)$$

其中, N 代表 N 个随机时间序列, k_{random} 是通过构建零模型并通过与步骤 2) 相同的操作得到的标准差。

步骤 4) 分析各组不同滑动窗方案的 K_{PLI} 值, 继而获得 HC, MCI 和 AD 组之间的差异性。并以此为依据分别确定在设计的滑动窗方案中适合 5 个频段的最佳滑动窗方案。

2.2 零模型

零模型的构建是通过数据增强的方法得到与原始

EEG 信号具有某些相似特征的信号并从中提取某些特征得到特征矩阵。零模型可以有选择性地保留大脑网络的特定属性, 同时系统地随机化其他特征。本文通过构建零模型得到与 k_{real} 对应的 k_{random} , 并根据式 (3) 得到网络的动态特性评估指标 K_{PLI} 。通过构建零模型, 使得 K_{PLI} 对大脑网络的随机性问题进行了充分的考虑。 Yi 等^[12]通过振幅调整傅里叶变换 (amplitude adjusted Fourier transform, AAFT) 构建了零模型。但是, 由于 AAFT 中的两个重排操作并不是彼此的逆操作, 导致替代数据相对于原始数据的功率谱密度存在一定的白化程度。

迭代振幅调整傅里叶变换 (iterative amplitude adjusted Fourier transform, IAAFT) 的基本思想是生成与原始数据具有相似特性的数据^[13], 其算法能够很好地匹配原始数据的傅里叶频谱和概率密度分布^[14]。采用 IAAFT 构建零模型的具体步骤如下:

步骤 1) 设原始时间序列数据为 $x(t)$ 。对 $x(t)$ 进行傅里叶变换得到 $x(f)$, 记录其幅值 $|x|$ 。

步骤 2) 取服从均匀分布的随机相位与 $x(f)$ 的相位相加实现相位的随机化, 并对结果进行逆变换得到 $y(t)$ 。

步骤 3) 通过对 $y(t)$ 进行傅里叶变换得到另一个序列 $y(f)$ 。

步骤 4) 使用 $|x|$ 代替 $y(f)$ 的幅值, 并进行傅里叶逆变换得到 $y'(t)$ 。

步骤 5) 重复步骤 4), 直至 $y'(t)$ 得到与 $x(t)$ 相似的功率谱密度。

步骤 6) 对所有通过时间窗划分的序列重复步骤 1)~5), 并将获得的随机时间序列 $x'(t)$ 的 PLI 矩阵作为零模型。

3 特征提取

3.1 相位滞后指数

PLI 反映了一个信号相对于另一个信号相位超前或滞后的一致性^[15], 是基于相位的功能连接方法, 可以用来衡量两个通道信号的相位同步程度, 其计算方法如下:

$$PLI = | \text{sign}(\Delta\varphi_{rel}(t)) | = \left| \frac{1}{N} \sum_{n=1}^N \text{sign}(\Delta\varphi_{rel}(t_n)) \right| \quad (4)$$

其中, N 表示时间点, $\Delta\varphi_{rel}(t_n)$ 表示两个通道信号在同一时间点 t_n 处的相位差, $\text{sign}(\cdot)$ 是符号函数, 当自变量为正值时, 其输出为 1, 当自变量的值为负值时, 其结果为 -1, 当自变量的值为 0 时, 其结果也是 0。

PLI 的取值范围为 $[0, 1]$, 值越大表明两个信号之间的相位同步程度越强。

3.2 连续小波变换

通过使用连续小波变换 (continuous wavelet transform, CWT) [16] 在时频域中分析 EEG 信号, 假设 $s(t)$ 是 n 个通道的 EEG 信号。则 CWT 定义如下:

$$CWT(a, b) = \frac{1}{\sqrt{a}} \int s(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (5)$$

其中, a 和 b 分别表示放缩和平移变量, ψ 表示的是母小波函数, $*$ 表示复共轭算子, 而 $CWT(a, b)$ 表示小波系数。

由于 Faust 等 [17] 已经证明墨西哥帽小波与 EEG 信号的动力学匹配效果良好, 故 CWT 选用的母小波函数为墨西哥帽小波函数。其定义式如下:

$$\psi(t) = \frac{1}{\sqrt{2\pi}\sigma^3} \left(e^{-\frac{t^2}{2\sigma^2}} \cdot \left(\frac{t^2}{\sigma^2} - 1 \right) \right) \quad (6)$$

其中, σ 为标准差。

对于各个频段, 在进行了 CWT 操作之后分别提取了 5 个特征, 分别是均值、标准差、偏度、峰度和模糊熵。

3.3 模糊熵

模糊熵是基于近似熵、样本熵提出的改进方法。模糊熵衡量的是新模式产生的概率大小, 测度值越大, 新模式产生的概率越大, 即序列复杂度越大。

对于给定的时间序列 $[u(1), u(2), \dots, u(N)]$, 定义相空间维度 $m (m \leq N-2)$ 和相似容限度 r , 重构相空间:

$$X(i) = [u(i), u(i+1), \dots, u(i+m-1)] - u_0(i), \quad i = 1, 2, \dots, N-m+1 \quad (7)$$

$$\text{其中, } u_0(i) = \frac{1}{m} \sum_{j=0}^{m-1} u(i+j).$$

引入模糊隶属度函数, 计算相似度:

$$A_{i,j}^m = e^{-\ln 2 * \left(\frac{d_{i,j}^m}{r} \right)^2} \quad (8)$$

其中, $d_{i,j}^m$ 为切比雪夫距离。

对于每一个 i , 求其平均值:

$$C_i^m(r) = \frac{1}{N - m_{j=1, j \neq i}} \sum A_{i,j}^m \quad (9)$$

令 $m \rightarrow m+1$, 重复上述的操作, 得到 $\phi^{m+1}(r)$ 。

对于有限长数据集, 模糊熵为:

$$\text{FuzzyEn}(m, r, N) = \ln \phi^m(r) - \ln \phi^{m+1}(r) \quad (10)$$

4 实验结果分析

4.1 滑动窗组合

本文首先对 5 个频段的 EEG 信号进行了不同滑动窗方案的分段处理, 并选择使用 K_{PLI} 对分段处理的结果进行评估, 得到使 K_{PLI} 最具有显著性差异的滑动窗方案。图 2 对各个频段最具有显著性的滑动窗方案的结果进行了展示。经过评估得到的各频段最佳滑动窗方案为: δ 波段: 滑动窗长度为 3 s, 窗口间的重叠率为 0%。 θ 波段: 滑动窗长度为 1 s, 窗口间的重叠率为 75%。 α 波段: 滑动窗长度为 1 s, 窗口间的重叠率为 50%。 β 波段: 滑动窗长度为 1 s, 窗口间的重叠率为 75%。 γ 波段: 滑动窗长度为 1 s, 窗口间的重叠率为 75%。




图 2 各频段 K_{PLI} 显著性结果 (图中的 + 表示平均值, * 代表 $p < 0.01$, ** 代表 $p < 0.005$, *** 代表 $p < 0.0001$)

Fig. 2 Significance results K_{PLI} frequency bands (+ in the graph represents the average, * represents $p < 0.01$, ** represents $p < 0.005$, *** represents $p < 0.0001$)

通过图 2 可知, 在 5 个频段中, HC 与 AD, MCI 与 AD 之间均存在显著性差异, HC 与 MCI 之间只有在 δ 波段存在显著性差异, 这表明在病情发展的初期, 即 MCI 阶段, 几乎和 HC 之间并不会太大的差异, 但随着病情的进一步发展, 当患者从 MCI 阶段过渡到 AD 阶段时, 大脑的动态特性已经产生了很大的变化。除 δ 频段外, 其他

频段的 HC 的 K_{PLI} 平均值均与 MCI 的 K_{PLI} 平均值几乎一致。以上两个发现表明当 HC 发展成为 MCI 时, 大脑内可能存在一种补偿机制来阻止大脑情况的进一步恶化, 使得大脑的动态特性保持不变, 但当患者发展成为 AD 时, 大脑内部的这种补偿机制几乎不在发挥任何作用, 使得大脑的动态特性产生了很大的变化。

4.2 相位滞后指数

对 PLI 的处理,是对各频段采取得到的最佳滑动窗

方案进行分段处理后,再进行 PLI 特征的提取。提取到的各频段的结果如图 3 所示。




图 3 各频段 PLI 特征显著性分析结果

Fig. 3 Results of PLI feature significance analysis results in each frequency band

通过对 PLI 显著性分析发现,各个频段的 MCI 与 AD,HC 与 AD 之间均存在显著性差异。这一结果与 K_{PLI} 指标的结果如出一辙,进一步表明在大脑内部可能存在一种补偿机制。

通过图 3 可知,除 δ 频段 HC 的 PLI 矩阵的平均值与 MCI 的平均值几乎一致以外,其他频段的 MCI 的 PLI 矩阵的平均值均相对于 HC 的平均值有一定程度上的增加。除 α 频段 AD 的 PLI 矩阵的平均值低于 HC 和 MCI 的平均值外,其他频段的 AD 的 PLI 矩阵的平均值均相对 MCI 的平均值有了进一步的提升。并且,AD 的 PLI

矩阵的平均值的增加程度明显大于 MCI 的平均值的增加。这可能是由于补偿机制的作用,使得在 MCI 阶段病情并没有出现明显的加重,仍然处于一种可控的状态,但当患者发展成为 AD 时,大脑的受损程度已经产生了很大程度上的发展,使得病情加重,超出可控范围。

4.3 连续小波变换

对于 CWT 的特征提取,是在进行了 CWT 处理后的各个频段分别提取了 5 个特征。因此,对 CWT 总共提取了 25 个特征。对其中模糊熵部分的结果如图 4 所示。




图 4 CWT 特征的模糊熵提取结果

Fig. 4 Fuzzy entropy extraction results of CWT features

通过图 4 可知,HC 与 MCI 患者之间在 δ 频段, α 频段和 β 频段均不存在显著性差异,这表明 HC 和 MCI 患者的大脑复杂性并未产生较大的变化。反观 MCI 患者与 AD 患者之间,除 δ 频段外的其他频段均存在显著性差异,这表明从 MCI 患者转变为 AD 患者的过程中,大脑的复杂度已经产生了显著性的变化。这一结果也进一步论证了之前的想法,即在大脑内部可能存在一种补偿机制。

5 ResNet-MLP 分类模型

目前,基于深度学习的自动模型备受关注,其在医学领域中某些疾病的诊断方面应用也越来越多。Ruiz-Gómez 等^[18]从 111 个 EEG 信息(37 个 HC,37 个 MCI 和 37 个 AD)中提取了一组光谱和非线性特征,并使用多层感知机 (multi-layer perceptron artificial neural network,

MLP)进行分类,准确率分别为 78.43%(HC vs. ALL)和 76.47%(AD vs. ALL)。Duan 等^[19]通过对 MCI 与 AD 患者的脑电信息构建高低阶网络,并进一步提取了网络的图论特征,其使用支持向量机(support vector machines, SVM)利用图论特征进行分类,得到了 83.3%(对于 MCI 数据集)和 85.4%(对于 AD 数据集)的分类准确率。使用 ResNet-18 残差深度学习网络利用高低阶网络进行分类,得到了 93.42%(对于 MCI 数据集)和 98.54%(对于 AD 数据集)的分类准确率。Mcbride 等^[20]从 15 名 HC、16 名 MCI 和 17 名 AD 的 EEG 信号中提取了基于区域频谱和复杂性的特征,并使用基于 SVM 的三向分类器分别

对睁眼静息状态、闭眼计数任务和闭眼静息状态的分类准确率为 83.3%、85.4%、79.2%。

本文采用了双通道模型来进行对 HC、MCI 和 AD 的分类,其中一条通道采用的是 ResNet-18 模型,用来对 PLI 特征进行特征提取,另一条通道采用 MLP,用来进行对从 CWT 中提取到的 25 个特征进行特征提取。随机选择 78 名受试者的特征作为训练集,batch_size 大小设置为 4,epoch 设置为 50,共进行了 1 000 次迭代。模型采取的学习速率为 0.002,激活函数选择使用 ReLU 函数,优化器运用 Adam,损失函数选择使用交叉熵损失函数,进行了 5 折交叉验证。模型的输入输出情况如图 5 所示。




图5 ResNet-MLP 双通道分类模型

Fig. 5 ResNet-MLP two-channel classification model

本文采取了如下组合进行分类:1)输入特征:CWT,分类模型:MLP;2)输入特征:PLI,分类模型:ResNet-18;3)输入特征:CWT&PLI,分类模型:ResNet-MLP 双通道。

通过对比分类结果的方式对特征融合的效果进行展示。分类得到的结果如表 1 所示。

表 1 模型分类结果
Table 1 Model classification results

个性化滑动窗分段处理	ACC	PRECISION	RECALL	F1_SCORE
CWT&PLI	82.2±0.02	73.2±0.04	71.1±0.05	72.2±0.05
CWT	60.0±0.04	68.1±0.05	52.2±0.04	64.3±0.04
PLI	74.4±0.01	67.0±0.07	66.7±0.05	68.7±0.05

同时为了将其与一般的固定窗分段方式进行对比,也进行了整体统一分段的处理。通过选取适合整体的滑动窗之后,对分段后的整体 EEG 信号通过滤波的形式得

到各频段信号,并对得到的各频段信号进行之前一样的操作步骤。得到的分类结果如表 2 所示。

表 2 整体分段结果对比
Table 2 Comparison of overall segmentation results

整体固定窗分段处理	ACC	PRECISION	RECALL	F1_SCORE
CWT&PLI	72.2±0.03	70.1±0.08	68.6±0.08	69.3±0.09
CWT	52.2±0.03	63.9±0.07	60.0±0.04	68.5±0.04
PLI	71.1±0.02	63.9±0.06	62.2±0.08	65.0±0.07

通过将表 1 和 2 的结果进行对比可以发现,对不同频段选取个性化滑动窗方案处理,对于分类效果上具有一定程度上的提升,尤其是在数据融合方面,虽然两者都有一定程度上的提升,但是前者的提升程度明显要大于后者。

6 结 论

本文首先通过 EEGLAB 对 EEG 信号进行降噪处理,再使用滤波器将信号分解成 5 个频段。对各频段采用 4 种滑动窗窗口长度和 4 种重叠率总计 16 种滑动窗方案对信号进行分段处理,并利用 K_{PLI} 对分段效果进行评估,得出最适合的滑动窗方案。通过对 K_{PLI} 的结果分析,猜测大脑中可能存在一种补偿机制,当大脑发生病变时,该机制会发挥用来减缓病变的进一步发展。之后对各频段提取了 PLI 特征以及 CWT 处理,并在 CWT 处理后提取了均值、标准差、偏度、峰度、模糊熵 5 个特征。本文设计了 ResNet-MLP 双通道分类网络来进行 HC, MCI, AD 的三分类,最终得到了 82.2% 的分类准确率。为了表明各频段进行不同分段处理具有一定程度上的优化,对各个频段采取了在整体上的固定窗统一分段处理,提取了相同的特征,并利用 ResNet-MLP 双通道分类网络进行了三分类操作,最终得到了 72.2% 的分类准确率。因此,对各个频段采取不同的分段方案可以作为一种有效提高分类准确率的方法。

参考文献

- [1] Alzheimer's Association. 2022 Alzheimer's disease facts and figures. *Alzheimers Dement.* 2022,18(4):700-789.
- [2] DUAN F, HUANG Z, SUN Z, et al. Topological network analysis of early Alzheimer's disease based on resting-state EEG [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2020, 28(10): 2164-2172.
- [3] 谢士遥,汤佳贝,蔡雨,等. 脑电 BCI 系统的软硬件开发平台发展现状[J]. *电子测量与仪器学报*, 2022, 36(6):1-12.
XIE SH Y, TANG J B, CAI Y, et al. Review on software and hardware platforms for EEG-based BCI system[J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(6):1-12.
- [4] ZHANG B, YANG Z, CAI H, et al. Ontology-Based decision support tool for automatic sleep staging using dual-channel EEG data [J]. *Symmetry*, 2020, 12(11):1921.
- [5] ELDELE E, CHEN Z, LIU C, et al. An attention-based deep learning approach for sleep stage classification with single-channel EEG [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2021, 29: 809-818.
- [6] HARVY J, THAKOR N, BEZERIANOS A, et al. Between-frequency topographical and dynamic high-order functional connectivity for driving drowsiness assessment [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2019, 27(3): 358-367.
- [7] LIAN H, LI Y, LI Y. Altered EEG microstate dynamics in mild cognitive impairment and Alzheimer's disease [J]. *Clinical Neurophysiology*, 2021, 132(11):2861-2869.
- [8] 赵亮,方芳,王伟,等. 基于脑电信号间 Granger 因果关系特征的情感识别[J]. *电子测量与仪器学报*, 2018, 32(6):87-95.
ZHAO L, FANG F, WANG W, et al. Emotion recognition based on Granger causality features between EEG signals[J]. *Journal of Electronic Measurement and Instrumentation*, 2018, 32(6):87-95.
- [9] YUN S, JEONG B. Aberrant EEG signal variability at a specific temporal scale in major depressive disorder [J]. *Clinical Neurophysiology*, 2021, 132(8):1866-1877.
- [10] TIAN Z, HU B, SI Y, et al. Automatic seizure detection and prediction based on brain connectivity features and a CNNs meet transformers classifier [J]. *Brain Sciences*, 2023, 13(5):820.
- [11] ROY A M. Adaptive transfer learning-based multiscale feature fused deep convolutional neural network for EEG MI multiclassification in brain-computer interface [J]. *Engineering Applications of Artificial Intelligence*, 2022, 116: 105347.
- [12] YI G, WANG L, CHU C, et al. Analysis of complexity and dynamic functional connectivity based on resting-state EEG in early Parkinson's disease patients with mild cognitive impairment [J]. *Cognitive Neurodynamics*, 2022, 16(2): 309-323.
- [13] XIN L, HAO Z, RUI S, et al. A mild cognitive impairment diagnostic model based on IAAFT and BiLSTM [J]. *Biomedical Signal Processing and Control*, 2023, 80.
- [14] 睦焯. 替代数据及其应用 [D]. 上海:华东师范大学, 2011.
SUI Y. Surrogate data and its application [D]. Shanghai:East China Normal University, 2011.
- [15] BIERE J, OKKERSEN K, ALFEN N V, et al. Characterization of EEG-based functional brain networks in myotonic dystrophy type 1 [J]. *Clinical Neurophysiology*, 2020, 131(8):1886-1895.
- [16] KANT P, LASKAR S H, HAZARIKA J, et al. CWT based transfer learning for motor imagery classification for

brain computer interfaces [J]. Journal of Neuroscience Methods, 2020, 345: 108886.

[17] FAUST O, ACHARYA U R, ADELI H, et al. Wavelet-based EEG processing for computer-aided seizure detection and epilepsy diagnosis [J]. Seizure, 2015, 26:56-64.

[18] RUIZ-GÓMEZ S J, GÓMEZ C, POZA J, et al. Automated multiclass classification of spontaneous EEG activity in Alzheimer's disease and mild cognitive impairment[J]. Entropy, 2018, 20(1): 35.

[19] DUAN F, HUANG Z, SUN Z, et al. Topological network analysis of early Alzheimer's disease based on resting-state EEG[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2020, 28(10): 2164-2172.

[20] MCBRIDE J C, ZHAO X, MUNRO N B, et al. Spectral and

complexity analysis of scalp EEG characteristics for mild cognitive impairment and early Alzheimer's disease [J]. Computer Methods and Programs in Biomedicine, 2014, 114(2):153-163.

作者简介



李昕(通信作者),2008 年于燕山大学获得博士学位,现为燕山大学教授、博士生导师,主要研究方向为脑机接口、神经反馈、信号处理以及神经工程。

E-mail: yddylixin@ysu.edu.cn

Li Xin (Corresponding author) received her Ph. D. degree from Yanshan University in 2008. Now she is a professor and Ph. D. supervisor in Yanshan University. Her main research interests include brain-computer interfaces, neurofeedback, signal processing, and neural engineering.