

DOI:10.19651/j.cnki.emt.2210541

# 基于时空和频域特征的 EEG 帕金森疾病识别 \*

杜淑慧<sup>1</sup> 何小海<sup>1</sup> 赵晓玲<sup>2</sup> 卿粼波<sup>1</sup> 陈洪刚<sup>1</sup>

(1. 四川大学电子信息学院 成都 610065; 2. 西南交通大学附属医院 &amp; 成都市第三人民医院 成都 610031)

**摘要:** 脑电图(EEG)中蕴含着有关脑功能的丰富信息,这些信息对不同类型神经系统疾病的检测和诊断非常重要。针对单一特征无法充分表达脑电信号的问题,本文融合了频域特征和时空信息来更好的对信号进行表征,并提出一种基于时空和频域特征的注意力网络(STFACN)用于帕金森疾病(PD)的自动检测。在频域角度,利用快速傅里叶变换法从多通道脑电图中求取 Delta、Theta、Alpha 频段的平均功率特征。同时构建基于时空特征的紧凑型卷积神经网络,并将通道注意力机制嵌入到网络中,自适应提取表征 PD 的时空特征。最后将基于频域特征的模型与基于时空特征的紧凑型卷积神经网络模型进行融合,在新墨西哥州大学(UNM)数据集上进行实验,特异性、敏感性、准确率分别达到 87.97%、84.39%、86.89%。在爱荷华大学(UI)数据集上进行跨数据集实验,准确率达到 77.33%。实验结果表明:与现有的方法相比,本文提出的方法能够从原始脑电图中挖掘出有效特征,在基于 EEG 的帕金森疾病识别问题上准确率高,泛化能力强。

**关键词:** 脑电信号; 频段平均功率; 时空特征; 通道注意力

中图分类号: TP181 文献标识码: A 国家标准学科分类代码: 510.4030

## EEG Parkinson's disease identification based on spatiotemporal and frequency domain feature networks

Du Shuhui<sup>1</sup> He Xiaohai<sup>1</sup> Zhao Xiaoling<sup>2</sup> Qing Linbo<sup>1</sup> Chen Honggang<sup>1</sup>

(1. College of Electronics and Information Engineering, Sichuan University, Chengdu 610065, China;

2. Affiliated Hospital of Southwest Jiaotong University &amp; The Third People's Hospital of Chengdu, Chengdu 610031, China)

**Abstract:** Electroencephalography (EEG) contains rich information about brain function, which is very important for the detection and diagnosis of different types of neurological diseases. In view of the fact that a single feature cannot fully express the EEG signal, this paper combines frequency domain features and spatiotemporal information to better represent the signal, and proposes an attention network based on spatio-temporal and frequency domain features (STFACN) for automatic detection of Parkinson's disease (PD). From the perspective of frequency domain, the average power characteristics of Delta, Theta and Alpha frequency bands were obtained from the multi-channel EEG using the fast Fourier transform method. In terms of spatiotemporal feature extraction, a compact convolutional neural network based on spatiotemporal features is constructed, and the channel attention mechanism is embedded into the network, and the adaptive extraction can characterize the effective features of PD. Finally, the model based on frequency domain features is fused with the compact convolutional neural network model based on spatiotemporal features, and experiments are carried out on the University of New Mexico (UNM) dataset. The specificity, sensitivity and accuracy reach 87.97%, 84.39% and 86.89% respectively. Cross-dataset experiments are performed on the University of Iowa (UI) dataset, and the accuracy rate reaches 77.33%. The experimental results show that compared with the existing methods, the method proposed in this paper can mine effective features from the original EEG, and has high accuracy and strong generalization ability in the EEG-based Parkinson's identification problem.

**Keywords:** EEG signal; frequency band average power; spatiotemporal features; channel attention

## 0 引言

帕金森病(Parkinson disease, PD)是第二常见的神经

退行性疾病,到 2030 年患病率将翻一番<sup>[1]</sup>。帕金森病是最普遍的一种运动障碍,是一种慢性、退行性、进行性疾病,也是仅次于阿尔茨海默病(Alzheimer disease, AD)的第二常

收稿日期:2022-07-01

\*基金项目:成都市重大科技应用示范项目(2019-YF09-00120-SN)资助

见的神经退行性疾病。PD 的平均起病年龄在 60 岁以上,然而,在极少数情况下,这些症状会在年轻人中出现得更早。神经退行性疾病是导致老年人脑功能和生活质量下降的主要原因,影响着 65 岁以上人群的 1%~2%。据调查显示,全球 PD 患者数量已从 1996 年的 250 万增加到 2016 年的 610 万,现在约为 1 000 万<sup>[2]</sup>。在帕金森病后期,患者曾出现运动型和非运动型的各种并发症。为了抵抗这些并发症,早期发现并准确诊断 PD 症状非常重要<sup>[3]</sup>。然而直到今天,PD 的起源仍然未知,同时由于缺乏帕金森病的治疗方法,研究早期 PD 检测方法非常重要,以便延缓疾病进展,从而提高患者的生活质量<sup>[4]</sup>。

帕金森病以运动迟缓、肌强直、静止性震颤等运动症状为特征性表现,并伴有便秘、嗅觉减退、抑郁、睡眠障碍等非运动症状<sup>[5]</sup>,此外在被诊断为 PD 的患者中,也经常观察到一系列非运动症状,如认知障碍、睡眠障碍和自主神经功能障碍<sup>[6]</sup>。这些情况都对 PD 患者的日常生活产生负面影响。目前,也有一些诊断帕金森病的技术:认知障碍测试和基于生理信号分析的技术<sup>[7]</sup>。

虽然在 PD 的诊断中有各种生理和病理学发现,但这些发现并不能为区分健康和疾病个体提供完整的证据<sup>[8]</sup>。在未观察到明显的运动或非运动症状时,该病的诊断有很大的困难。现阶段没有明确的单一生物标志物,可以准确地对早期 PD 进行检测,也不能通过脑部扫描或其他测试能够明确诊断帕金森病。目前最有效的方法仍然是在 PD 初始阶段或左旋多巴疗效较低的情况下,由医生根据患者的病史、行为和交叉询问进行临床诊断,同时通过后续随访,重新评估患者的身体和神经症状<sup>[9]</sup>。然而,明显的运动症状可能只有当大多数多巴胺能神经元丢失时才存在,因此当个体还没有明显的体征或症状时,诊断可能会很困难。对于那些早期 PD 患者,早期前驱症状起着至关重要的作用。帕金森病已是一种日益严重的威胁,对患者的生活质量有着重大影响,利用临床特征来重新评估帕金森病初期或左旋多巴作用较弱时的物理和神经症状这一过程具有主观性,因此迫切需要一种客观诊断方法辅助医生对帕金森患者的诊疗提供支持,以检测帕金森病的初始阶段。脑电图(electroencephalogram,EEG)是一种非侵入性技术,具有高时间分辨率的特点,可以快速评估瞬时脑功能,此外,它对脑血流量和神经代谢的急性变化表现出良好的敏感性<sup>[10]</sup>。脑电信号被定义为大脑皮层不同位置记录到的电信号,反映了相应大脑区域神经元产生的放电情况<sup>[11]</sup>,其缺点是背景噪声强且信号微弱<sup>[12]</sup>。

近年来,脑电图信号被广泛用于该疾病的早期检测。Wyman 等<sup>[13]</sup>使用了各种认知损害测试,以评估目前的临床能力,以便在 PD 早期检测轻度认知损害(mild cognitive impairment,MCI),总体准确率达到 67.4%,但是认知损害测试容易存在漏洞,且耗费时间。Cavanagh 等<sup>[14]</sup>提出了一种从脑电图诊断早期帕金森病的方法,通过主成分分析

(principal component analysis,PCA)从脑电信号中提取一些光谱特征和七个时间因子,使用支持向量机作为分类器,获得了 82% 的准确率,但分析仅限于光谱特征和时间特征,没有考虑脑电信号空间维度的特征。Chu 等<sup>[15]</sup>提出了一种时空 EEG 微状态分析方法用于无药患者,他们的研究得出结论,PD 可以以不同于健康受试者的独特空间微状态表达,但是此方法主要利用统计分析来识别 PD 和正常被试,没有对脑电图深层次的信息进行挖掘。Geraedts 等<sup>[16]</sup>以脑电时间序列为输入,预测类别标签为输出,对 112 例帕金森病患者应用全自动机器学习管道进行分类,在帕金森自动分类任务中可获得高准确度,但是此方法主要用于接受脑深部电刺激筛查程序的 PD 患者。Wang 等<sup>[17]</sup>提出了一种利用插值方法将脑电信号的频带能量映射到二维图像上的方法,并基于胶囊网络对帕金森疾病进行分类识别,并发现伽玛频段的准确率最高,为 PD 的早期诊断和临床治疗提供了潜在的特征指标,但是该方法主要从频域和空间两方面开展工作,没有充分利用脑电图时间维度的特征。

基于上述问题,本文提出了一种基于时空和频域特征的注意力网络(spatio-temporal-frequency attention convolutional network,STFACN)用于帕金森疾病的自动检测。由于单一特征无法从多方面对脑电信号进行分析,本文提取不同频段的平均功率作为脑电信号的频域表征。同时通过将通道注意力模块嵌入到基于 CNN 的紧凑型卷积神经网络中,提取脑电信号时空特征。并在新墨西哥州大学数据集(University of New Mexico,UNM)上进行实验,同时为了验证本文提出方法的有效性和泛化性,在爱荷华大学(University of Iowa,UI)数据集上进行跨数据集实验。

## 1 本文模型及方法

本文提出的方法可分为 4 个步骤:数据预处理、特征提取、模型融合和分类,算法流程如图 1 所示。

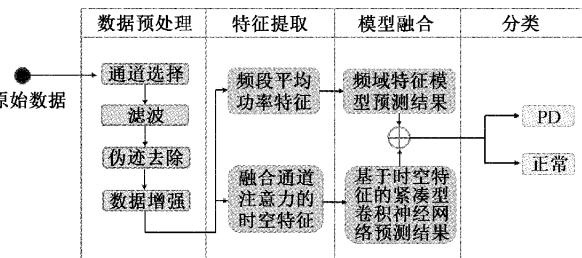


图 1 本文提出算法的整体框架

### 1.1 脑电信号预处理

为了提取有价值的信息,脑电信号的预处理非常重要。本文对脑电信号的预处理主要包括通道选择、滤波、伪迹去除和数据增强四部分。

**通道选择:**由于 UNM 数据集与 UI 数据集通道数不一致,本文分别去除 UNM 和 UI 数据集的参考电极 CPz 与 Pz,保留两个数据集共有的 62 个通道。

**滤波:**使用四阶的巴特沃斯带通滤波器对脑电信号进行滤波操作。截止频率设置为 $0.5\sim12\text{ Hz}$ ,同时滤除 $60\text{ Hz}$ 的工频频率。

**伪迹去除:**使用基于盲源分离中的独立主成分分析方法把信号分解成相互独立的多个源信号,去除眼动、心电和肌电引起的伪迹。

**数据增强:**由于数据集的样本量比较小,为了使实验效果尽可能好,本文使用了两种数据增强方式,一是对样本进行分割,二是给信号添加随机噪声。在开始训练前,先将信号分成 $1\text{ s}$ 的短序列,本文对UNM数据集采取时间上无重叠、重叠 $30\%$ 和重叠 $50\%$ 的方式进行分割。由于UI数据集用于验证模型的泛化性,因此只使用无重叠的方式进行分割。

图2为未经预处理的PD患者脑电信号,图3为预处理之后的PD患者脑电信号,图4为预处理之后的正常受试者脑电信号。通过观察可以发现,正常受试者与PD患者所产生的脑电信号是有区别的,这就说明利用EEG信号识别帕金森疾病成为可能。

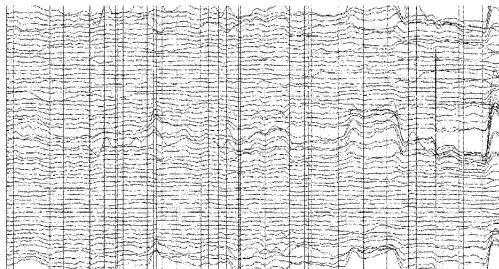


图2 未经预处理的PD患者脑电信号

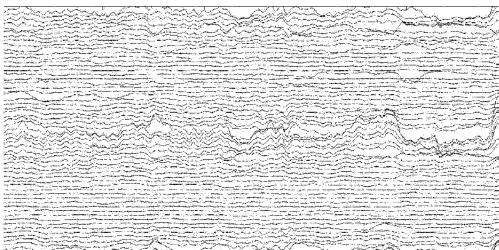


图3 预处理之后的PD患者脑电信号

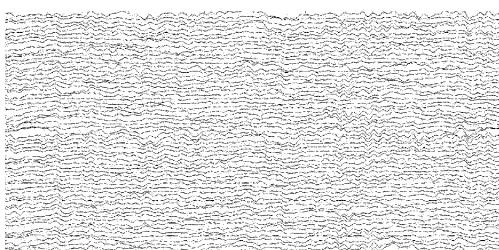


图4 预处理之后的正常受试者脑电信号

对于同一患者,其不同时间段内的自身状态会使其脑电产生变化。不同患者之间个体差异也会引起脑电的差异,因此为了使结果更加可靠,同时提高模型的泛化性能,

本为对脑电数据进行Z-score标准化处理,其计算如式(1)所示。

$$x(k)' = \frac{x(k) - \bar{x}}{s} \quad (1)$$

其中,  $\bar{x}$  表示信号的均值,  $s$  表示信号的标准差,  $x(k)'$  表示归一化后的信号幅度值。

## 1.2 网络模型

本文提出的STFACN模型框架如图1第3列所示。第1部分为脑电信号Delta、Theta、Alpha子频段平均功率特征的提取,从频域角度分析PD患者与正常对照组的脑电差异,并使用多种分类器验证特征矩阵的有效性。第2部分为基于时空特征的紧凑型卷积神经网络,网络包含时空特征的提取与通道自注意力机制。通过将注意力模块嵌入到构建好的卷积神经网络中提取输入特征图各通道之间的相互依赖关系并对原始的特征图进行矫正。最后本文使用间隔法进行权重系数的搜索,寻找两个模型对应的最佳权重值。

## 1.3 频域特征提取

本文根据预处理后的信号对 $0.5\sim12\text{ Hz}$ 的频段进行分析,将预处理后的脑电信号分解为Delta、Theta、Alpha三个频段的信号,各子频带频率范围及相应描述如表1所示。接着通过快速傅里叶变换计算每个通道不同子频段的能量,计算过程如式(2)和(3)所示。

$$X(k) = \text{FFT}[x(n)] = \sum_{n=0}^{N-1} x(n) e^{\frac{-j2\pi kn}{N}}, k = 0, 1, \dots, N-1 \quad (2)$$

$$E = X(k) \cdot X(k)^T \quad (3)$$

其中,FFT表示快速傅里叶变换过程,N表示样本采样点个数,x(n)为原始信号,X(k)为经过傅里叶变换后的信号,E表示信号的能量,X(k)<sup>T</sup>表示X(k)的转置。再根据能量计算每个子频段的平均功率,最后将所有子频段的平均功率值拼成一个一维向量,作为脑电的频域特征,计算过程如式(4)和(5)：

$$P = \frac{E}{N} \quad (4)$$

$$T = \text{concat}(P_1, P_2, \dots, P_m) \quad (5)$$

P表示频段平均功率,concat代表拼接操作,P<sub>m</sub>表示第m个样本,T代表拼接后的特征矩阵。最后将特征矩阵分别在RUSBoost、SVM、KNN、RF分类器下进行分类。

表1 PD信号子频带及活动描述

波形	频带/Hz	活动描述
$\delta$	$0.5\sim3$	极度疲劳和深度睡眠时
$\theta$	$4\sim7$	遭受挫折或精神抑郁时
$\alpha$	$8\sim12$	处于清醒、安静、闭眼时

## 1.4 时空特征提取

本文构建的基于时空特征的紧凑型卷积神经网络用于对帕金森疾病进行分类,网络框架如图5所示,Conv表示

卷积层, Att 表示注意力模块, Output 表示输出层。

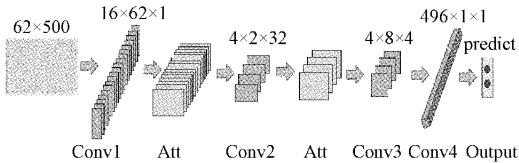


图 5 基于时空特征的紧凑型卷积神经网络模型

考虑到 EEG 的低信噪比、数据集小、随着模型复杂性的增加,会导致过度拟合等问题。本文构建了四层紧凑型 CNN 架构,用于脑电信号时空特征的提取。该模型在第 1 层和第 3 层进行空间特征的提取,在第 2 层进行时间特征提取,迭代地聚集空间和时间维度上的信息,以紧凑的方式表征脑电信号。模型的输入为预处理后 1 s 的脑电信号,输入尺寸为  $62 \times 500$ 。

在第 1 层,学习了 16 个大小为  $62 \times 1$  的卷积核,用于提取脑电信号每个时间点的空间特征,接着使用 ELU 激活函数得到非线性映射结果,ELU 计算可由式(6)表示:

$$ELU(x) = \begin{cases} x, & x \geq 0 \\ e^x - 1, & x < 0 \end{cases} \quad (6)$$

沿着特征映射维度进行归一化操作来提高模型的泛化性和稳定性。为了防止在训练时出现过拟合同时减少网络参数,本文设置 dropout 为 0.25。最后将输出进行转置,以生成新的二维时间序列。最后使用数据填充操作。第 2 层首先在第 1 层输出特征上学习 4 个大小为  $2 \times 32$  的二维卷积核。接着使用  $2 \times 4$  的最大池化操作实现降维。第 3 层,学习了 4 个大小为  $8 \times 4$  的二维卷积核,同样也使用  $2 \times 4$  的最大池化实现特征的降维。第 2 层与第 3 层中的 ELU 激活函数、归一化、dropout、数据填充操作与第一层一致。在第 4 层中,首先对第三层输出的特征做均值池化,然后送入 FC,其输出经过 softmax 函数得到两类的概率值,最终取概率较大值对应的类别为模型预测结果。

本文使用交叉熵(cross entropy)作为损失函数,主要进行帕金森和正常两种类别区分,属于 0~1 分布,交叉熵损失函数可用式(7)表示。

$$H(p, q) = - \sum_x (p(x) \log q(x) + (1-p(x)) \log(1-q(x))) \quad (7)$$

其中,  $p$  表示模型期望输出的概率,  $q$  表示模型实际输出的概率。

## 1.5 注意力模块

本文构建的通道注意力模块如图 6 所示,通过将该模块嵌入到 CNN 中自适应地重新校准特征映射,以增强有意义的特征,同时抑制较弱的特征。由于每个通道上的特征矩阵代表不同卷积核所表示的分量。将特征信息分解成  $C$  个卷积核上的信息,这  $C$  个信息分量具备原始脑电信号全部的关键信息点,若为这  $C$  个通道分配不同的权重,即可表示不同通道分量与脑电信号关键信息的相关性,计算

出这些相关性就可以注意到图像脑电信号的关键部分,达到排除无用信息的目的。

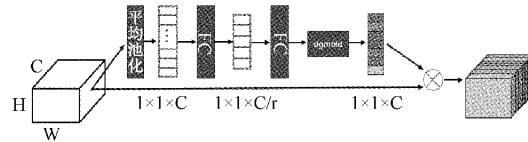


图 6 通道注意力模块网络架构

本文使用全局平均池化对输入的特征映射  $X = [x_1, x_2, \dots, x_n]$  进行操作,其中  $x_i \in R^{H \times W}$  代表各个通道,生成一个  $1 \times 1 \times C$  的向量记作  $z$ 。即分别对各个通道的值全部加起来取平均,来从空间维度整合特征图。该向量包含了通道特征响应的全局分布,能够获取全局感受野的信息,计算过程如式(8):

$$z_m = \frac{1}{H \times W} \sum_i^H \sum_j^W x_m(i, j) \quad (8)$$

$z_m$  指压缩后  $z$  向量中的第  $m$  个值,  $x_m(i, j)$  是输入特征图的第  $m$  层,第  $i$  行第  $j$  列的值,  $H$  是特征图的高,  $W$  是特征图的宽。

之后使用两个全连接层对  $z$  向量进行编码,得到各个通道的重要度  $z'$ ,在第一个全连接层后使用 ReLU 激活函数对该向量进行非线性操作,计算过程如式(9)所示。

$$z' = W_2(ReLU(W_1 z)) \quad (9)$$

$W_1, W_2$  分别为第 1 个全连接层和第 2 个全连接层的权重。

最后通过一个 sigmoid 函数将通道重要度映射到  $[0, 1]$  区间内,将生成的权重向量与原始特征图相乘,达到对原始特征图重新校准的目的,计算过程如式(10)所示。

$$X' = [x_1 \sigma(z'_1), x_2 \sigma(z'_2), \dots, x_n \sigma(z'_n)] \quad (10)$$

其中,  $X'$  为重新加权的特征图,  $\sigma$  表示 sigmoid 操作,重新加权的特征图作为后续层中的输入继续参与训练。

## 1.6 分类

通过融合频域特征模型与引入注意力之后的卷积神经网络模型(spatio-temporal attention convolutional network, STACN)模型,得出最后的分类结果。本文通过在  $[0, 1]$  区间内以 0.05 的宽度进行搜索,计算两个模型的权重值,最终为 STACN 分配 0.60,为频域特征模型分配 0.40。

## 2 实验结果及分析

### 2.1 数据集

新墨西哥州大学数据集包含帕金森患者 27 名,正常对照组 27 名。以 500 Hz 的频率采集受试者 64 个电极完全松弛状态下睁眼和闭眼时的脑电,参考电极设置为 CPz。对于帕金森患者的脑电图采集包括两个阶段,分别是记录药物治疗阶段的脑电和记录最后一次服用多巴胺能药物 12 h 后的脑电。正常对照组和帕金森患者在年龄和性别上相匹配,在教育程度和患病前智力水平的测量标准上没有

任何差异。

爱荷华大学数据集包括 14 名帕金森患者和 14 名正常对照组。所有数据使用 64 通道的脑视觉系统采集,信号频率范围为 0.1~100 Hz,采样率为 500 Hz,参考电极设置为 Pz。所有受试者均采集静息状态时的头皮脑电。28 名受试者只记录其睁眼时的脑电。

## 2.2 实验设置

本文实验的硬件配置为 36 核 Inter(R) Xeon(R) E5-2686,内存大小为 11 GB,使用 Nvidia 1080 Ti 进行加速。软件环境为 Ubuntu16.04 系统。实验超参数设置如下:批处理大小(batch size)设置为 256,训练次数为 50 epoch。参数优化器为 Adam,L2 正则化系数设置为 1,初始学习率为 0.0001,每间隔一定的 epoch 对学习率进行更新,更新方式如式(11)。

$$\text{new\_lr} = \text{initial\_lr} \times \gamma^{\text{epoch}/\text{step\_size}} \quad (11)$$

其中,initial\_lr 表示初始学习率,γ 表示更新学习率的乘法因子,设置为 0.5。step\_size 表示 epoch 间隔次数,设置为 30。

## 2.3 评价指标

为验证本文所提算法对于帕金森疾病检测任务的有效性,本文使用特异性(specificity)、灵敏性(sensitivity)和准确率(accuracy)作为评价指标。并通过混淆矩阵中真阳性(true positive, TP)、假阳性(false positive, FP)、真阴性(true negative, TN)和假阴性(false negative, FN)的值计算指标结果。其中真阳性率表示将帕金森患者判为帕金森的概率,真阴性率表示将正常受试判为正常的概率。

## 2.4 实验结果

表 2 所示为将 3 个频段的平均功率特征作为输入,分别在 RUSBoost、SVM、KNN、RF 分类器下的性能对比。实验采用五折交叉验证。根据表 2 可以得出,Delta、Theta、Alpha 频段的平均功率可以在一定程度上表征脑电信号的频域特征,并且能较好的识别 PD 患者与正常被试。在 4 个分类器中 SVM 分类器的分类性能最佳,获得了 74.46% 的灵敏性,75.02% 的特异性,74.74% 的准确率。实验结果表明,本文提取的频域特征矩阵可以有效地捕捉和表征输入信号的特征属性,如相对位置、尺度、方向等之间的关系。基于此,本文使用该特征矩阵,并选取 SVM 分类器对频域特征进行分类。

表 2 融合 3 个频段平均功率的特征在多个分类器下的性能

频域特征	分类器	TPR/%	TNR/%	Acc/%
混合 平均 功率	RUSBoost	64.34	64.72	64.53
	SVM	<b>74.46</b>	<b>75.02</b>	<b>74.74</b>
	KNN	70.3	60.68	65.42
	RF	63.82	66.25	65.05

为了实现对 PD 患者更精准的检测,本文使用空间和

时间迭代的紧凑型卷积神经网络进行脑电信号特征提取,同时引入通道注意力机制自适应地对特征通道进行矫正,并将该注意力模型集成到构建好的紧凑型卷积神经网络结构中参与训练。为了验证该算法的有效性,分别对频域特征模型、未加注意力的卷积神经网络模型(spatio-temporal convolutional network, STCN) 和 STACN 进行实验,其分类结果如表 3 所示。TPR 指标表示 PD 患者的检测是否存在漏诊,该值越大,表明模型对于患者的检测能力越强。由表 3 可以看出,在引入通道注意力模块后,TPR 相比频域特征模型提升了 12.12%,比 STCN 提升了 1.73%,同时 TNR、Acc 均高于频域特征模型和 STCN。说明引入通道注意力的模型对于 PD 患者的检测能力有所提高。

表 3 频域特征、STCN、STACN 分类结果对比

方法	UNM		
	TPR/%	TNR/%	Acc/%
频域特征	74.46	75.02	74.74
STCN	84.85	78.48	82.94
STACN	<b>86.58</b>	<b>81.21</b>	<b>84.97</b>

将频域特征模型与 STACN 模型进行融合,并将融合后的网络(STFACN)的分类结果与其他方法进行对比,对比结果如表 4 所示。由表可知,融合后的模型 STFACN 相较于频域特征模型和 STACN 模型都有一定程度上的提升,说明融合频域特征与时空特征能更好的表征帕金森患者的脑电信号。

表 4 STFACN 与不同算法结果对比

方法	UNM		
	TPR/%	TNR/%	Acc/%
文献[18]	74.1	70.4	72.2
文献[19]	63	55.7	59.3
文献[20]	70.4	74.1	72.2
文献[21]	87.9	82.7	85.3
文献[22]	81.7	84.32	83.01
频域特征	74.46	75.02	74.74
STACN	86.58	81.21	84.97
STFACN	<b>87.97</b>	<b>84.39</b>	<b>86.89</b>

Chaturvedi 等<sup>[18]</sup> 使用惩罚逻辑回归方法证明大脑某些区域在  $\theta$ 、 $\alpha_2$  和  $\beta$  功率及  $\alpha_1/\theta$  比值上存在差异,将他们的方法应用于 UNM 数据集上整体识别准确率达到 72.2%。Yuvaraj 等<sup>[19]</sup> 提取 HOS 双谱特征用于 PD 和健康对照组分类。经实验,他们的方法在 UNM 数据集上获得 59.3% 的准确率。Vanneste 等<sup>[20]</sup> 利用丘脑皮层节律障碍模型对脑的振荡机制进行研究,并使用 SVM 分类器进行分类,在 UNM 数据集上获得 72.2% 的准确率。Anjum 等<sup>[21]</sup> 提

出的 LEAPD 方法在 UNM 数据集获得 85.3% 的准确率。Khoshnevis 等<sup>[22]</sup>提取 30 个高阶和 6 个低阶统计特征进行分类,经实验,他们的方法在 UNM 数据集上得到 83.01% 的准确率。

与上述方法相比,本文构建的 STFACN 模型在 UNM 数据集上的准确率较文献[18-22]中提出的方法分别提升 14.19%、27.59%、14.19%、1.59% 和 3.88%。结果表明该模型能学到有效的 PD 脑电特征表示,能够对 1 s 的输入数据进行学习,自动提取脑电信号中深层次的特征。

## 2.5 算法泛化性验证

为了评估本文提出方法的稳健性和有效性,我们通过增加受试者之间的可变性,在 UI 数据集上进行验证。表 5 为本文提出方法 STFACN 在 UI 数据集上的实验结果。

表 5 STFACN 在 UI 数据集实验结果

方法	UI		
	TPR/%	TNR/%	Acc/%
STFACN	74.52	80.09	77.33

实验表明,本文提出的算法在 UI 数据集上取得了优异的性能指标,获得 74.52% 的灵敏性、80.09% 的特异性、77.33% 的准确率。

## 3 结 论

本文介绍了一种基于时空和频域特征的注意力网络用于帕金森疾病的自动检测。我们发现 Delta、Theta、Alpha 频段的平均功率特征对于帕金森疾病的分类有一定效果。其次使用紧凑型卷积神经网络对脑电信号进行时空特征的迭代提取,并且引入通道注意力机制,对卷积神经网络的输出特征通道进行自动矫正,最后我们使用网格搜索法获得两个模型的权重,并对模型进行融合。实验结果表明,本文提出的方法在帕金森疾病自动检测上的灵敏性、特异性、准确率优于其他方法。同时跨数据集实验表明,本文提出的模型泛化能力、稳定能力强。文本的模型有望对 PD 患者的自动检测提供新的技术支持。目前,本文的工作是基于静息态的头皮脑电,数据形式比较单一,今后将结合多源数据进行更深层次的信息挖掘。

## 参考文献

- [1] AARSLAND D, BATZU L, HALLIDAY G M, et al. Parkinson disease-associated cognitive impairment[J]. Nature Reviews Disease Primers, 2021, 7(1): 1-21.
- [2] PARASHOS S A, BLOEM B R, BROWNER N M, et al. What predicts falls in Parkinson disease?: Observations from the Parkinson's Foundation registr[J]. Neurology: Clinical Practice, 2018, 8(3): 214-222.
- [3] HALOI R, HAZARIKA J, CHANDA D. Selection of appropriate statistical features of EEG signals for detection of Parkinson's disease [C]. 2020 International Conference on Computational Performance Evaluation (ComPE), IEEE, 2020: 761-764.
- [4] DASTGHEIB Z A, LITHGOW B, MOUSSAVI Z. Diagnosis of Parkinson's disease using electrovestibulography [J]. Medical & Biological Engineering & Computing, 2012, 50(5): 483-491.
- [5] 田敏, 刘艺鸣. 帕金森病相关呼吸功能障碍研究进展[J]. 中国现代神经疾病杂志, 2022, 22(4): 229-236.
- [6] POEWE W, SEPPI K, TANNER C M, et al. Parkinson disease[J]. Nature reviews Disease primers, 2017, 3(1): 1-21.
- [7] SILVA G, ALVES M, CUNHA R, et al. Parkinson disease early detection using EEG channels cross-correlation [J]. Int J Appl Eng Res, 2020, 15: 197-203.
- [8] VANEGAS M I, GHILARDI M F, KELLY S P, et al. Machine learning for EEG-based biomarkers in Parkinson's disease [C]. 2018 IEEE International Conference on Bioinformatics and Biomedicine(BIBM), IEEE, 2018: 2661-2665.
- [9] PADMANABHAN S, POLINSKI N K, MENALLED L B, et al. The Michael J. Fox Foundation for Parkinson's research strategy to advance therapeutic development of PINK1 and Parkin[J]. Biomolecules, 2019, 9(8): 296.
- [10] AJGEVIĆ M, FURLANIS G, MILADINOVIC A, et al. Early EEG alterations correlate with CTP hypoperfused volumes and neurological deficit: A wireless EEG study in hyper-acute ischemic stroke[J]. Annals of Biomedical Engineering, 2021, 49(9): 2150-2158.
- [11] 高越, 傅湘玲, 欧阳天雄, 等. 基于时空自适应图卷积神经网络的脑电信号情绪识别[J]. 计算机科学, 2022, 49(4): 30-36.
- [12] 张学军, 陈都, 孙知信. 基于卷积神经网络的脑电信号情绪分类方法[J]. 电子测量技术, 2022, 45(1): 1-7.
- [13] WYMAN-CHICK K A, MARTIN P K, BARRETT M J, et al. Diagnostic accuracy and confidence in the clinical detection of cognitive impairment in early-stage Parkinson disease[J]. Journal of Geriatric Psychiatry and Neurology, 2017, 30(3): 178-183.
- [14] CAVANAGH J F, KUMAR P, MUELLER A A, et al. Diminished EEG habituation to novel events effectively classifies Parkinson's patients[J]. Clinical Neurophysiology, 2018, 129(2): 409-418.
- [15] CHU C, WANG X, CAI L, et al. Spatiotemporal EEG microstate analysis in drug-free patients with

- Parkinson's disease[J]. NeuroImage: Clinical, 2020, 25: 102132.
- [16] GERAEDTS V J, KOCH M, CONTARINO M F, et al. Machine learning for automated EEG-based biomarkers of cognitive impairment during Deep Brain Stimulation screening in patients with Parkinson's Disease[J]. Clinical Neurophysiology, 2021, 132(5): 1041-1048.
- [17] WANG S, WANG G, PEI G. An EEG-based approach for Parkinson's disease diagnosis using capsule network [C]. 2022 7th International Conference on Intelligent Computing and Signal Processing(ICSP), IEEE, 2022: 1641-1645.
- [18] CHATURVEDI M, HATZ F, GSCHWANDTNER U, et al. Quantitative EEG(QEEG) measures differentiate Parkinson's disease(PD) patients from healthy controls (HC)[J]. Frontiers in Aging Neuroscience, 2017, 9: 1-7.
- [19] YUVARAJ R, ACHARYA U R, HAGIWARA Y. A novel Parkinson's disease diagnosis index using higher-order spectra features in EEG signals [J]. Neural Computing and Applications, 2018, 30(4): 1225-1235.
- [20] VANNESTE S, SONG J J, DE RIDDER D. Thalamocortical dysrhythmia detected by machine learning[J]. Nature Communications, 2018, 9 (1): 1-13.
- [21] ANJUM M F, DASGUPTA S, MUDUMBAI R, et al. Linear predictive coding distinguishes spectral EEG features of Parkinson's disease[J]. Parkinsonism & Related Disorders, 2020, 79: 79-85.
- [22] KHOSHNEVIS S A, SANKAR R. Classification of the stages of Parkinson's disease using novel higher-order statistical features of EEG signals[J]. Neural Computing and Applications, 2021, 33(13): 7615-7627.

### 作者简介

杜淑慧,硕士研究生,主要研究方向为脑电信号处理与识别。

E-mail:1033407692@qq.com

何小海(通信作者),教授,博士生导师,主要研究方向为图像处理、模式识别、计算机视觉、图像通信和软件工程等。

E-mail:nic5602@scu.edu.cn

赵晓玲,主任医师,主要研究方向为神经变性疾病,认知障碍疾病,脑血管病。

E-mail:1156133699@qq.com

卿粼波,教授,博士生导师,主要研究方向为图像处理、视觉计算、数据挖掘、视频编码和传输等。

E-mail:qing\_lb@scu.edu.cn

陈洪刚,副研究员,主要研究方向为图像处理与计算机视觉。

E-mail:honggang\_chen@scu.edu.cn