

基于 KAN 的多模态自动睡眠分期^{*}

张昌涛^{1,2} 耿读艳^{1,2} 殷 明^{1,2}

(1. 河北工业大学省部共建电工装备可靠性与智能化国家重点实验室 天津 300130;

2. 河北工业大学电气工程学院 天津 300072)

摘要:当前的自动睡眠分期模型存在特征提取能力不足以及多模态特征融合效果欠佳的问题。为了更有效地处理非线性信号,本文利用科尔莫戈罗夫-阿诺德网络(KAN)动态学习非线性激活函数,采用基于 KAN 和迁移学习的特征提取网络分别提取睡眠状态下的脑电和心电信号特征。利用外部注意力机制对不同模态分别施加注意力,通过结合外部注意力机制的多模态门控融合方案进行特征整合,缓解数据类不平衡对 N1 期精度的影响。在 ISRUC-S3 数据集上实现了 85.6% 的总体准确率、84.9% 的宏平均 F_1 值, N1 期的 F_1 分数为 67.7%。相较于当前的其他先进方法,有效提升了自动睡眠分期算法的性能。

关键词:自动睡眠分期;科尔莫戈罗夫-阿诺德网络;迁移学习;外部注意力机制;多模态门控融合

中图分类号: TN911 **文献标识码:** A **国家标准学科分类代码:** 520.2040

Multimodal automatic sleep staging based on KAN

Zhang Changtao^{1,2} Geng Duyan^{1,2} Yin Yue^{1,2}

(1. State Key Laboratory of Reliability and Intelligence of Electrical Equipment, Hebei University of Technology, Tianjin 300130, China; 2. School of Electrical Engineering, Hebei University of Technology, Tianjin 300072, China)

Abstract: The current automatic sleep staging model has the problems of insufficient feature extraction ability and poor multimodal feature fusion effect. In order to deal with nonlinear signals more effectively, the Kolmogorov-Arnold networks (KAN) is used to dynamically learn nonlinear activation functions, and the feature extraction network based on KAN and transfer learning is used to extract the features of EEG and ECG signals in sleep state respectively. The external attention mechanism is used to apply attention to different modalities respectively, and the multi-modal gated fusion scheme combined with the external attention mechanism is used for feature integration to alleviate the influence of data class imbalance on N1 stage accuracy. On the ISRUC-S3 dataset, we achieve an overall accuracy of 85.6%, a macro-average F_1 value of 84.9%, and an F_1 score of 67.7% for N1 stage. Compared with other advanced methods, the performance of the automatic sleep staging algorithm is effectively improved.

Keywords: automated sleep staging; Kolmogorov-Arnold networks; transfer learning; external attention mechanism; multimodal gated fusion

0 引言

随着现代生活节奏的加快,睡眠障碍问题愈发普遍,不仅影响日常生活的质量,还与心血管疾病和糖尿病等慢性疾病有关^[1]。睡眠主要分为清醒期(wake, W)、非快速眼动(NREM)睡眠和快速眼动(REM)睡眠。NREM 睡眠进一步细分为 3 个阶段:N1、N2 和 N3。睡眠分期有助于睡眠质量评估和有关病症的早期诊断。

传统的睡眠分期方法依赖于专业技术人员通过视觉检

查多导睡眠图(PSG)记录来完成,耗时且主观性强。自动化睡眠分期方法利用机器学习或深度学习算法自动执行,旨在提高效率并减少人为错误。基于深度学习的睡眠分期方法相比传统机器学习方法具有显著优势,能够自动从原始数据中提取特征并进行端到端的学习^[2]。Zhou 等^[3]提出融合黎曼流形特征和卷积神经网络的分层模型,通过序列相关性机制实现睡眠分期,在 ISRUC-S3 数据集上的准确率为 0.837。Ji 等^[4]引入跳跃知识机制的时空图卷积网络,优化信息传递效率,准确率为 0.831。Ji 等^[5]结合 3 D

卷积和图卷积网络, 通过多通道生理信号同时提取时空和频域特征, 准确率为 0.83。现有算法的睡眠分期精确度不高, 面临着三大问题: 首先, 由于大脑涉及大量的神经元相互作用, 脑电(EEG)信号具有复杂的非线性关系, 而现有方法线性变换局限性显著, 难以有效提取 EEG 信号中的长时间序列的全局特征。其次, 在多模态融合方面, 虽然 JK-STGCN^[4] 和 MixSleepNet^[5] 模型综合利用了脑电、眼电、心电、肌电信号, 但其使用的多模态融合机制并不完善, 自动睡眠分期模型性能提升有限。并且针对数据类不平衡问题的解决能力不足, N1 阶段的分期精度明显较低。

为了提升对 EEG 信号的特征提取能力, 本文提出了一种基于 KAN^[6] 的模型结构。相较于传统多层感知机(MLP)及其衍生架构(如 Transformer)依赖线性组合与固定激活函数的局限^[7], KAN 通过参数化非线性激活函数(如样条函数)实现了动态学习机制。不仅突破了线性建模的瓶颈, 还通过自主优化网络结构显著提升了模型表征能力和参数效率。此外, 在心电(ECG)的特征提取上, 因其具有明确形态基元(QRS 波)和长程周期关联, 所以使用具有局部层次敏感性和周期结构扩展性的深度残差网络 18(ResNet18)架构, 采用迁移学习策略, 加载预训练模型、复用其权重, 并针对 ECG 任务调整结构。在多模态特征融合上, 本文使用结合外部注意力机制的门控特征融合模块来综合利用 EEG 与 ECG 信号, 外部注意力机制凭借全局记忆单元高效捕获多模态信号的跨域关联, 显著提升特征融合的全局感知能力。门控融合机制能够动态调节模态权重分布, 缓解特征冲突与类不平衡问题, 强化模型决策鲁棒性。通过融合特征提升分期精度, 尤其是增强对 N1 期的分期效果。

1 模型设计与方法

1.1 基于 KAN 网络的特征提取模块

1) KAN 网络的结构和应用

如图 1 所示, KAN 网络通过消除对线性权重矩阵的依赖, 采用参数化的非线性激活函数(如 spline 函数)进行动态学习和优化, 同时具备了 MLP 和样条结构的优势, 与使用固定激活函数的 MLP 模型相比, KAN 能够直接学习并优化非线性激活函数, 其通用公式为:

$$KAN(x) = (\mathcal{O}_{L-1} \circ \mathcal{O}_{L-2} \circ \cdots \circ \mathcal{O}_1 \circ \mathcal{O}_0)(x) \quad (1)$$

其中, \mathcal{O}_i 表示可学习的激活函数, 这些函数通常以样条函数形式参数化为式(2)形式。这一操作使得每个权重参数都可以被一个单变量函数替换, 从而提供了极高的灵活性。与传统的 MLP 中使用的固定激活函数(例如 ReLU 或 Sigmoid)相比, KAN 对于非线性激活函数的使用和优化机制显著提升了模型在捕捉信号内在复杂性方面的多样性和适应性。

$$\mathcal{O}_{q,p}(x_p) = \sum_i c_i B_i(x_p) \quad (2)$$

系数 c_i 在训练过程中通过梯度下降等优化方法来最小化损失函数。

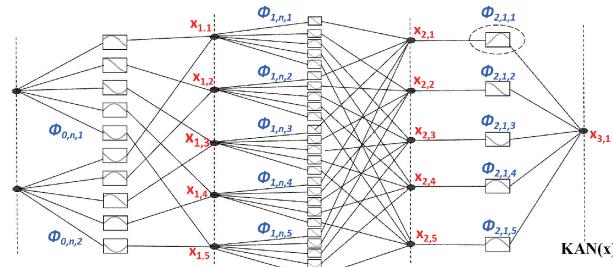


图 1 KAN 网络的架构

Fig. 1 Architecture of the KAN

针对传统线性变换在处理复杂时间序列数据时难以有效捕捉非线性特征的局限性, KAN 网络在其基础上嵌入了基于 B 样条的非线性变换机制。这一创新显著提升了特征的非线性映射能力, 使得模型能够更为精准地识别和解析数据中的复杂模式, 从而大幅提升了分期性能。KAN 结构中集成的激活函数符号化、可视化、稀疏性正则化及剪枝技术, 有效剔除了特征提取模型中的冗余参数^[6], 实现了在维持高精度分期效果的同时, 显著提升了模型的参数效率。

2) 通道注意力机制

通道注意力机制^[8]通过动态调整特征通道的重要性来增强深度神经网络的特征表达能力。该机制首先对输入特征图进行深度维度的平均池化, 随后利用小卷积层实现通道的缩减和扩展, 并结合非线性激活函数生成通道注意力权重。同时, 通过自适应平均池化和全连接层序列生成另一组权重。最终, 将这两组权重与原始输入特征图相乘, 输出通道重要性自适应调整后的特征图。

在 EEG 特征提取的最终阶段引入该机制, 可对经 KAN 等网络处理后的特征进行全局优化, 实现通道间依赖关系的自适应学习, 从而提升网络对关键特征的识别能力。

3) 基于 KAN 网络的脑电特征提取结构

本研究首次将 KAN 网络架构应用于多模态睡眠分期任务的脑电信号特征提取, 旨在克服传统 MLP 在非线性信号处理上的局限, 提升脑电信号表征能力。如图 2 所示, EEG 信号经卷积层初步提取特征, 随后通过最大池化层降维并保留关键特征, 再经 Dropout 层防过拟合。首个 KAN 模块提取浅层睡眠 EEG 特征, 继以两个卷积层进一步提取, 再经最大池化层降维。第二个 KAN 模块深入挖掘深层特征, 通过残差连接融合原始与提取特征, 增强表达。同时, 另一组卷积和池化层并行提取特征。最终, 两路径特征拼接, 经 Dropout 层增强泛化能力, 并引入通道注意力机制提升关键特征敏感性。

1.2 基于 ResNet18 迁移学习的特征提取模块

迁移学习首先利用大规模标注数据集对模型进行预训练, 使模型能够学习并捕捉数据的基本特征, 从而获得初步的识别能力。随后, 将预训练后的模型迁移至目标小规模

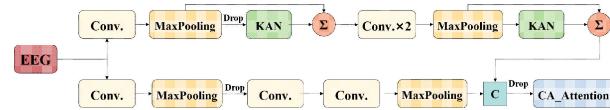


图 2 基于 KAN 网络的 EEG 特征提取结构

Fig. 2 Structure of EEG feature extraction based on KAN

数据集,并通过对少量标注数据的微调,使模型适应新数据集的特性。鉴于睡眠分期任务中标注数据的采集往往充满挑战,迁移学习显著降低了对大规模标注数据集的依赖性。

如图 3 所示,在具体的实现过程中,本研究采用了 ResNet18 结构^[5],将其迁移到本文的睡眠分期特征提取任务中进行微调,以实现对 ECG 信号特征的提取。该网络的权重层数为 18,残差连接分为 4 个阶段,每个阶段包含 2 个输出通道数相同的残差块,其中,残差块的计算公式为:

$$H(x) = F(x) + x \quad (3)$$

其中, x 是残差块的输入, $F(x)$ 是残差函数, 表示通过两个卷积层处理后的输出, $H(x)$ 是残差块的输出。这种设计使得网络能够直接学习输入与输出之间的残差,从而更容易微调优化,并且使得在使用更深的睡眠信号特征提取和融合网络时,能够有效避免梯度衰减问题。

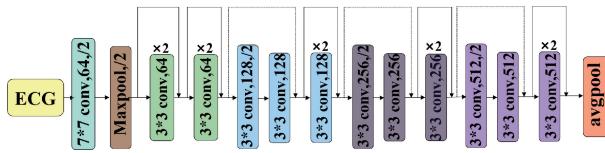


图 3 基于 ResNet18 网络的 ECG 特征提取结构

Fig. 3 Structure of ECG feature extraction based on ResNet18

1.3 多模态融合模块

1) 外部注意力机制

外部注意力机制通过精细调整参数实现特征提取过程的灵活定制,从而增强模型对多模态数据特征的适应性,并提升处理多模态输入的能力^[10]。

外部注意力机制可以描述如下:

$$\alpha_i = \frac{\exp(e_i)}{\sum_{i=1}^n \exp(e_i)} \quad (4)$$

其中, α_i 是第 i 个输入的注意权重, e_i 是模型计算出的相应能量分数, 用于评估每个输入模态的重性。

使用注意力权重进行的特征调整如下:

$$z_i = \sum_{j=1}^n \alpha_j h_j \quad (5)$$

其中, z_i 表示针对第 i 个输入的调整特征。

如图 4 所示,相较于自注意力机制,外部注意力机制中的 Key 和 Value 并非直接由输入特征的线性变换生成,而是存储于外部记忆单元。该单元能习得整个数据集样本的统计特征,帮助模型捕捉全局信息,进而深化对上下文的理解。通过引入两个线性单元作为记忆单元,运算复杂度显著降低,尤其适用于处理睡眠分期信号等长序列数据。

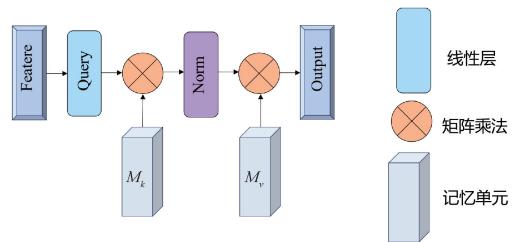


图 4 外部注意力机制结构

Fig. 4 Structure of the external attention mechanism

在睡眠分期任务中,通过引入外部注意力机制,聚焦于 EEG 和 ECG 信号中最具信息量的部分,滤掉噪声和无关信息,显著提升了模型的鲁棒性。模型可以更好地理解不同模态之间的交互,有助于利用两种数据源的互补信息。

2) 门控融合机制

本研究引入了门控融合模块,旨在通过门控机制增强 EEG 和 ECG 模态特征的整合。门控机制^[11]借鉴自循环网络中的信息传播控制,可形式化表述为:

$$g = \sigma(W_g x + b_g) \quad (6)$$

其中, g 是门控向量, σ 是 S 型激活函数, W_g 和 b_g 分别为门控机制的权重和偏置项。门控融合后的最终特征集成由以下公式给出:

$$h = g \odot h_a + (1 - g) \odot h_x \quad (7)$$

其中, \odot 表示逐元素乘法, h_a 是经过外部注意力处理的特征, h_x 是原始输入特征。

$$z = \sigma(W_z x + b) \quad (8)$$

引入门控机制的首要作用在于其能学习并调整特征的重要性,有助于解决数据类不平衡问题。通过 sigmoid 激活函数(式(8)),该机制可自适应地调整输入特征权重,以更好地适应特定任务。在融合特征时能考虑全局上下文信息,强化了模型对多模态输入中全局关系的捕捉能力。其次,卷积层、激活函数与线性层的协同作用,使模块能对输入特征执行非线性变换,从而提升对复杂模式与关系的建模能力,这与多模态分类任务的目标相契合。

1.4 多模态睡眠分期模型

EEG 与 ECG 信号分别提供了关于大脑和心脏活动在睡眠过程中的不同层次的生理信息,EEG 特征在清醒阶段分期中贡献较大,而 ECG 特征在深度睡眠阶段分期中贡献较大。本模型旨在通过多层次、全方面的睡眠信号特征提取与融合,全面捕捉 EEG 和 ECG 信号特征,从而实现睡眠阶段的精确区分。

本文设计了两个独立的特征提取网络,分别针对 EEG 和 ECG 信号,通过多层次卷积和最大池化操作逐步提取高层次特征,并引入 Dropout 层防止过拟合。此外,采用 KAN 网络动态调整非线性激活函数,采用通道注意力机制增强关键通道的特征。如图 5 所示,在特征提取后,利用外部注意力机制对不同模态的特征图进行加权,并通过多模态门控融合方案整合 EEG 和 ECG 特征。最后,整合后的特征

通过分类器进行睡眠状态分期。

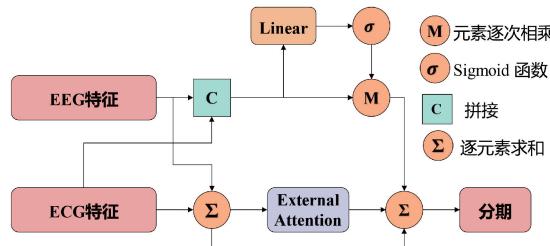


图 5 自动睡眠分期模型结构

Fig. 5 Architecture of the automated sleep staging model

为了充分挖掘 EEG 与 ECG 信号的协同信息, 本研究采用了分别针对各模态计算损失函数、并进行联合优化的训练策略, 以促进两种模态间的信息共享, 实现特征的整合与相互补充。

2 实验设计与结果分析

2.1 数据集与设置说明

本研究选取的公开数据集为 ISRUC-S3^[12], 该数据集由 10 名受试者的 8 549 个生理信号样本组成, 含有多导联的信号记录及相应的标签信息, 每个 PSG 记录包含 6 个 EEG 通道、2 个 EOG 通道、3 个 EMG 通道和 1 个 ECG 通道。覆盖了睡眠周期的各个阶段, 每个睡眠阶段的样本数量和所占比例展示如表 1 所示。

表 1 各睡眠阶段样本数和所占比例

Table 1 Sample size and percentage of each sleep stage

参数	W	N1	N2	N3	REM
样本数	1 651	1 215	2 609	2 014	1 060
比例	19.3%	14.2%	30.5%	23.6%	12.4%

为了确保实验结果的可靠性和模型的泛化能力, 本研究采用了 10 折交叉验证方法。为了适配模型的输入需求, EEG 和 ECG 信号采用了滑动窗口技术进行分段处理。每个窗口的持续时间设定为 30 s, 这一选择遵循了国际睡眠分期的相关标准。每个信号段被标注为相应的睡眠阶段 (W、N1、N2、N3、REM), 从而构建了用于模型训练与验证的标准化数据输入。

本研究中的所有实验均在 Pytorch2.1.0 中使用 Python3.8 编译代码, 并使用 NVIDIA RXT 4060 显卡进行加速, 根据 Table 2 设置的超参数进行训练。

2.2 评估指标

为了全面评估模型的分期性能, 选择了准确率 (accuracy, ACC)、精确率 (precision)、召回率 (recall, R)、 F_1 分数 (F_1 -score, F_1)、宏平均 F_1 分数 (macro averaging F_1 -score, MF_1) 这 5 个指标, 衡量模型对睡眠分期的性能, 超参数设置如表 2 所示, 计算公式分别为:

表 2 超参数设置

Table 2 Hyperparameter setting

超参数	值
训练轮数	30
优化器	Adam
学习率	0.001
Dropout 概率	0.2
随机种子	42
焦点损失参数 gamma	2

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$

$$precision = \frac{TP}{TP + FP} \quad (10)$$

$$R = \frac{TP}{TP + FN} \quad (11)$$

$$F_1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (12)$$

$$MF_1 = \frac{\sum_{i=1}^C F_{1i}}{C} \quad (13)$$

其中, TP 为正确分类的正例, TN 为正确分类的负例, FP 为错误分类为正例的负例, FN 为错误分类为负例的正例, C 为类别总数。

2.3 实验结果与对比分析

利用 ISRUC-S3 数据集进行实验, 并将本研究提出的模型与 4 个先进的基准模型进行了对比, 分别为 DeepSleepNet^[13]、GraphSleepNet^[14]、TS-AGCMM^[15]、MSTGCN^[16]。

其中, DeepSleepNet^[13] 结合卷积神经网络 (CNN) 和双向长短时记忆网络 (BiLSTM)。GraphSleepNet^[14] 结合图卷积网络和时空注意力机制。TS-AGCMM^[15] 结合时间自注意力和自适应图卷积。MSTGCN^[16] 使用多视图时空图卷积网络结合域泛化方法。这些算法通过模块的改进与组合创新, 逐渐提升睡眠分期性能。

由表 3 可知, 本文的睡眠分期模型在整体准确率上比文献[13-16]分别高 13.2%、4.7%、4.4%、2.5%。宏平均 F_1 值比文献[13-16]分别高 15.6%、5.4%、5.4%、3.6%。特别是对于最难分类的 N1 期提升明显, 比文献[13-16]分别高 25.5%、11.2%、12.1%、9.2%。本研究通过模块的改进与组合创新, 建立了更优的自动睡眠分期系统。

2.4 消融实验

为了验证各模块对于自动睡眠分期系统的作用, 设置了只使用 EEG 信号进行睡眠分期的实验 A, 只使用 ECG 信号的实验 B, 对 EEG 和 ECG 信号均使用基于 KAN 的特征提取结构的实验 C, 以及原实验 D。在同样的 ISRUC-S3 数据集上进行实验, 对比各阶段的 F_1 指标值。

表 3 与其他先进方法的结果对比

Table 3 Comparison with the results of other state of the art methods

数据集	模型	总体指标		各阶段的 F_1			
		ACC	MF ₁	W	N1	N2	N3
ISRUC-S3	DeepSleepNet ^[13]	0.724	0.693	0.842	0.422	0.759	0.853
	GraphSleepNet ^[14]	0.809	0.795	0.881	0.565	0.797	0.876
	TS-AGCMM ^[15]	0.812	0.795	0.883	0.556	0.799	0.887
	MSTGCN ^[16]	0.831	0.813	0.893	0.585	0.821	0.891
	本文	0.856	0.849	0.933	0.677	0.834	0.923

结合表 3 和表 4, 实验 A 的 MF₁ 分数高于 GraphSleepNet^[14] 和 TS-AGCMM^[15] 模型的实验结果, 证明了基于 KAN 的脑电特征提取结构对睡眠分期的贡献。实验 C 的 MF₁ 分数低于实验 D, 体现了基于迁移学习的 resnet18 特征提取模块对 ECG 信号特征提取的有效性。实验 D 的 MF₁ 分数高于实验 A、B, 尤其是 N1 期的 MF₁ 分数提高明显, 验证了结合外部注意力机制的门控特征融合模块对分期性能提升和缓解数据类不平衡性的作用。

表 4 消融实验结果对比

Table 4 Comparison of ablation experiment results

实验	F ₁ / %					MF ₁ / %
	W	N1	N2	N3	REM	
A	93.2	58.6	81.9	89.2	79.5	80.5
B	81.5	41.2	65.7	72.3	82.3	68.6
C	91.6	56.9	82.2	89.5	82.5	80.5
D	93.3	67.7	83.4	92.3	87.7	84.9

2.5 泛化实验

为了进一步验证 KAN 对于 EEG 的特征提取效果, 使用基于 KAN 的 EEG 睡眠分期模型, 利用 Sleep-EDF-153^[17] 的 Fpz-Cz 脑电通道数据进行进一步地实验, 并与其他先进模型进行对比, 包括使用 CNN-BiLSTM 的 DeepSleepNet^[13]、使用 CNN 和双向循环神经网络的 SleepEEGNet^[18] 以及使用多分辨率卷积神经网络的 AttnSleep^[19]。

从表 5 中可以看到, 与其他先进模型相比, 本方法的准确率和 MF₁ 分数均为最高。这证明了本文提出的基于 KAN 的 EEG 特征提取模块能够显著提升 EEG 信号中复杂时频特征的表达能力, 有效解决了对于复杂非线性电生理信号的处理问题, 且具有较强的泛化能力。

表 5 与其他脑电睡眠分期模型对比

Table 5 Comparison with other EEG sleep staging models

模型	ACC / %	MF ₁ / %
DeepSleepNet ^[13]	77.8	75.3
SleepEEGNet ^[18]	80	73.6
AttnSleep ^[19]	81.3	75.1
本文方案	83.7	75.6

3 结论

本文提出了一种基于 KAN 的多模态自动睡眠分期方法, 旨在解决现有深度学习方法在睡眠信号特征提取和多模态特征融合方面的局限性。通过引入 KAN 网络动态学习非线性激活函数, 提升特征提取能力, 有效地克服了传统网络结构在处理复杂非线性信号时的不足。结合更适合处理 ECG 信号的迁移学习 ResNet18 结构分别提取 EEG 和 ECG 信号的特征, 并利用外部注意力机制和门控融合方案实现特征整合, 降低数据类不平衡的影响。本文方法在 ISRUC-S3 数据集上取得了显著的性能提升。实验结果表明, 本文提出的模型在总体准确率为 0.856, 宏平均 F_1 值为 0.849, 均优于现有的其他先进方法, 证明了本模型的先进性, 尤其是 N1 期的 F_1 分数为 0.677, 加强了小样本阶段的分期性能, 提升了临床应用的可行性。未来的研究中, 应该在更多样化的临床数据集上验证模型的泛化能力, 确保模型在不同人群中的表现稳定。

参考文献

- [1] AAKRE J A, SCHULZ J, BALLARD C, et al. Self-reported sleep fragmentation and sleep duration and their association with cognitive function in PROTECT, a large digital community-based cohort of people over 50 [J]. International Journal of Geriatric Psychiatry, 2023, 38(11): e6022.
- [2] 陈玲玲, 毕晓君. 基于残差收缩网络的睡眠脑电分期 [J]. 仪器仪表学报, 2022, 43(2): 148-155.
- [3] CHEN L L, BI X J. Sleep EEG staging based on the residual shrinkage network [J]. Chinese Journal of Scientific Instrument, 2022, 43(2): 148-155.
- [4] ZHOU X, GUO Z, LIU J, et al. A hierarchical neural network on riemannian manifold and convolutional neural network for sleep stage classification [C]. 2024 IEEE International Symposium on Medical Measurements and Applications (MeMeA), 2024: 1-6.
- [5] JI X, LI Y, WEN P. Jumping knowledge based spatial-temporal graph convolutional networks for

- automatic sleep stage classification [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2022, 30: 1464-1472.
- [5] JI X, LI Y, WEN P, et al. MixSleepNet: A multi-type convolution combined sleep stage classification model [J]. Computer Methods and Programs in Biomedicine, 2024, 244: 107992.
- [6] LIU Z, WANG Y, VAIDYA S, et al. KAN: Kolmogorov-arnold networks [J]. ArXiv preprint arXiv: 2404.19756, 2024.
- [7] 李兰亭,苗敏敏. 基于多视图与注意力机制的睡眠脑电分期[J]. 国外电子测量技术, 2024, 43(1): 30-37.
- LI L T, MIAO M M. Sleep EEG staging based on multi-view and attention mechanism [J]. Foreign Electronic Measurement Technology, 2024, 43(1): 30-37.
- [8] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11534-11542.
- [9] LONGON A. Interpreting the residual stream of ResNet18[J]. ArXiv preprint arXiv: 2407.05340 2024.
- [10] GUO M H, LIU Z N, MU T J, et al. Beyond self-attention: External attention using two linear layers for visual tasks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 45(5): 5436-5447.
- [11] SUN Z, JIN D, DENG J, et al. Feature fusion module based on gate mechanism for object detection[C]. 2023 IEEE International Conference on Robotics and Biomimetics(ROBIO), 2023: 1-6.
- [12] KHALIGHI S, SOUSA T, SANTOS J M, et al. ISRUC-Sleep: A comprehensive public dataset for sleep researchers [J]. Computer Methods and Programs in Biomedicine, 2016, 124: 180-192.
- [13] SUPRATAK A, DONG H, WU C, et al. DeepSleepNet: A model for automatic sleep stage scoring based on raw single-channel EEG[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2017, 25(11): 1998-2008.
- [14] JIA Z, LIN Y, WANG J, et al. GraphSleepNet: Adaptive spatial-temporal graph convolutional networks for sleep stage classification [C]. The Twenty-Ninth International Joint Conference on Artificial Intelligence Main Track, 2021: 1324-1330.
- [15] CHEN Z, SHI W, ZHANG X, et al. Temporal self-attentional and adaptive graph convolutional mixed model for sleep staging[J]. IEEE Sensors Journal, 2024, 24(8): 12840-12852.
- [16] JIA Z, LIN Y, WANG J, et al. Multi-view spatial-temporal graph convolutional networks with domain generalization for sleep stage classification[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2021, 29: 1977-1986.
- [17] GOLDBERGER A L, AMARAL L A N, GLASS L, et al. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals[J]. Circulation, 2000, 101(23): e215-e220.
- [18] MOUSAVI S, AFGHAH F, ACHARYA U R. SleepEEGNet: Automated sleep stage scoring with sequence to sequence deep learning approach[J]. PloS One, 2019, 14(5):0216456.
- [19] 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.

作者简介

张昌涛(通信作者),硕士研究生,主要研究方向为生物电磁技术。

E-mail:2317197838@qq.com

耿读艳,博士,教授,博士生导师,主要研究方向为生物电磁技术。

E-mail: dygeng@ hebut.edu.cn

殷玥,博士研究生,主要研究方向为生物电磁技术。

E-mail:202411401028@stu.hebut.edu.cn