

## 基于CNN-BiGRU和多头自注意力机制的自动睡眠分期方法

张晓莉<sup>1,2</sup>, 张喜珍<sup>1,2</sup>, 林冬梅<sup>3</sup>, 陈扶明<sup>2</sup>

1. 甘肃中医药大学医学信息工程学院, 甘肃 兰州 730000; 2. 中国人民解放军联勤保障部队第九四〇医院医疗保障中心, 甘肃 兰州 730050; 3. 兰州理工大学电气与信息工程学院, 甘肃 兰州 730050

**【摘要】**针对睡眠脑电数据存在类别不平衡以及深层网络在提取更多特征时可能出现的梯度消失或爆炸现象问题。本文首先通过改进的自适应合成采样技术对少样本类别的睡眠脑电数据进行数据增强。然后, 利用卷积神经网络和残差网络学习数据特征, 并通过三层双向门控循环网络挖掘深层时序信息, 确定各睡眠阶段之间的相关性, 实现自动特征学习和睡眠周期提取。最后, 采用多头自注意力机制增强模型对序列中重要部分的关注, 完成各睡眠阶段的分类。实验结果表明, 根据AASM睡眠分期标准, 在经过数据类平衡处理后, 基于CNN-BiGRU和Multi-head Self Attention自动睡眠分期模型在Sleep-EDF-20数据集上的总准确率和Kappa系数分别达到了90.77%和0.88, N1期的精确率达到了87.1%; 在Sleep-EDFx数据集上MF1为0.84, N1期的精确率也达到了77.2%, 总体较CNN-BiGRU自动睡眠分期模型在原始数据集上的性能有所提升, 与其他相关研究相比, 睡眠阶段分类精度显著提升。验证了本文方法的有效性和泛化能力。

**【关键词】**睡眠分期; 类平衡; 残差网络; 双向门控循环网络

**【中图分类号】**R318

**【文献标志码】**A

**【文章编号】**1005-202X(2025)04-0496-09

### Automatic sleep staging method based on CNN-BiGRU and multi-head self-attention mechanism

ZHANG Xiaoli<sup>1,2</sup>, ZHANG Xizhen<sup>1,2</sup>, LIN Dongmei<sup>3</sup>, CHEN Fuming<sup>2</sup>

1. School of Medical Information Engineering, Gansu University of Chinese Medicine, Lanzhou 730000, China; 2. Medical Security Center, the 940th Hospital of Joint Logistics Support Force of Chinese People's Liberation Army, Lanzhou 730050, China; 3. School of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China

**Abstract** The study aims to address the issues of class imbalance in sleep EEG data and gradient vanishing or explosion phenomena that may occur when deep networks extract more features. An improved adaptive synthetic sampling technique is firstly employed to perform data augmentation on the minority classes of sleep EEG data. Subsequently, convolutional neural networks and residual networks are utilized to learn data features, while a 3-layer bidirectional gated recurrent network is applied to explore deep temporal information and establish correlations between different sleep stages, enabling automatic feature learning and sleep cycle extraction. Finally, a multi-head self-attention mechanism is adopted to enhance the model's focus on critical parts of the sequence, thereby completing the classification of various sleep stages. Experimental results show that according to the AASM sleep staging criteria, the automatic sleep staging model integrating CNN-BiGRU and multi-head self attention achieves an overall accuracy of 90.77% and a Kappa coefficient of 0.88 on the Sleep-EDF-20 dataset after data class balancing, with the precision of N1 stage reaching 87.1%. On the Sleep-EDFx dataset, the model attains an MF1 score of 0.84 while maintaining a precision of 77.2% for N1 stage classification. These metrics demonstrate significant improvements in performance as compared with CNN-BiGRU model tested on the original dataset. When benchmarked against other related studies, the proposed architecture exhibits superior sleep stage classification accuracy. These findings collectively validate the effectiveness and generalization capability of the proposed method.

**Keywords** sleep stage; class balance; residual network; bidirectional gated recurrent network

**【收稿日期】**2024-09-12

**【基金项目】**国家自然科学基金(61901515, 62361038); 甘肃省自然科学基金(22JR5RA002); 联勤保障部队第九四〇医院院内项目(2023YXKY018)

**【作者简介】**张晓莉, 硕士研究生, 研究方向: 医学信号检测与处理, E-mail: zxlxr86@163.com

**【通信作者】**陈扶明, 博士, 高级工程师, 硕士研究生导师, 研究方向: 医学信号检测与处理, E-mail: cfm5762@126.com

## 前言

睡眠对人类的大脑和身体功能起着关键作用,人的一生中约有1/3的时间都在睡眠中度过。高质量的睡眠作为一项重要的生理活动,有助于人类维持正常的认知和身体状况,而长期睡眠剥夺或紊乱会严重影响身心健康。研究表明某些疾病,如帕金森病和阿尔茨海默病,与睡眠障碍或异常密切相关<sup>[1-2]</sup>。睡眠分期不仅奠定研究睡眠本质基础,而且是睡眠诊断和治疗的重要因素,临床中要诊断睡眠障碍如阻塞性睡眠呼吸暂停以及罕见病如嗜睡症等疾病,大多通过睡眠阶段时长、睡眠周期、睡眠潜伏期和入睡后清醒时间等潜在的神经生理过程<sup>[3]</sup>,健康人在睡眠过程中会经历多个睡眠阶段的周期性循环,而有睡眠问题的患者则表现出睡眠结构的周期性不明显或较为紊乱。因此,进行睡眠阶段的准确评分,对于提高睡眠质量、预防睡眠障碍引起的疾病非常重要。

目前,睡眠评分是确定睡眠质量和诊断睡眠障碍的常用方法,一般基于多导睡眠图(Polysomnogram, PSG)进行,被认为是评估人类睡眠的黄金标准<sup>[4]</sup>。PSG又称睡眠脑电图,是通过身体不同部位的传感器获取的多种生物电信号,包括脑电信号(Electroencephalogram, EEG)、眼电信号(Electrooculography, EOG)、心电信号(Electrocardiogram, ECG)、肌电信号(Electromyogram, EMG)等<sup>[5-6]</sup>。睡眠EEG包含大量与人体疾病和生理相关的信息,在临床上常被用作诊断脑类疾病的依据。1968年,美国学者 Rechtschaffen 和 Kales 提出了早期的睡眠分期标准,即R&K标准<sup>[7]</sup>,将睡眠阶段划分为清醒期(Awake)、非快速眼动期(NREM)和快速眼动期(REM),其中NREM阶段进一步细分为S1、S2、S3、S4四个阶段。后来,美国睡眠医学学会提出了AASM标准<sup>[8]</sup>,合并了S3和S4阶段,将睡眠阶段划分为Wake、N1、N2、N3和REM五个阶段。传统的睡眠阶段分类是由睡眠专家将PSG数据划分为30 s的片段,又称为epoch,并观察每一个epoch时域信号的形态,结合相邻时段的信息,将每个epoch分配到一个睡眠阶段来实现的。这个过程不仅费时,且分类结果容易受到专家的可变性和主观性的影响<sup>[9]</sup>。因此有学者基于传统机器学习研究自动睡眠阶段分类方法。如Zaman等<sup>[10]</sup>使用时域和频域特征,利用一种基于多级树的集成模型,通过基于奖励的自适应权重分配进行调整,使用特征工程块的过滤特征对睡眠阶段进行分类,表现出卓越的性能,准确率为86.3%,Kappa得分为0.807; Satapathy等<sup>[11]</sup>将频率、时间和非线性统计特征进行融合,利用AdaBoost

将Sleep-EDFx的数据进行五分类,准确率达到96.40%。现有研究表明,基于手工特征的机器学习方法在自动睡眠评分中具有良好的效果。然而,这些方法的结果高度依赖于手工提取的特征类型以及数据集的依赖性,因此,经训练的机器学习模型的性能和适用性可能取决于给定的数据集,并且存在效率低、泛化性不足等缺点。

随着深度学习技术的持续进步,许多研究者致力于通过深度学习算法提升分类效率,开发自动睡眠分期模型。其中,卷积神经网络(Convolutional Neural Networks, CNN)用于提取部分时域特征,残差网络(Residual Network, ResNet)则用于解决深层模型中的梯度消失与爆炸问题。长短期记忆网络(Long Short-Term Memory, LSTM)和门控循环单元(Gate Recurrent Unit, GRU)等循环神经网络(Recurrent Neural Network, RNN)主要用于捕捉时序特征并学习睡眠阶段之间的转换规律,而注意力机制则用于学习时序的上下文信息。如Li等<sup>[12]</sup>采用CNN与LSTM以及CNN与双向LSTM(Bidirectional Long Short-Term Memory, BiLSTM)的自动睡眠分期方法,分别取得80.7%和82.5%的整体分期准确率,其中N1期的分期准确率仅为30.1%和38.9%;Li等<sup>[13]</sup>利用1D-ResNet块从单通道原始EEG中提取多级特征,LSTM网络捕获睡眠阶段之间的转换规则,总体准确率为86.4%,且使用加权交叉熵损失函数解决类别不平衡问题,从而导致N1阶段性能的显著改善,准确率达到59.1%;Liu等<sup>[14]</sup>将多尺度注意力ResNet和双向门控循环网络(Bidirectional Recurrent Neural Network, BiGRU)结合进行睡眠分期,Sleep-EDF数据集上的分类准确率为84.24%,N1期召回率达到67.2%;Jirakittayakorn等<sup>[15]</sup>利用不同损失函数权重的CNN模型用于特征提取,BiLSTM用于序列分类使用Sleep-EDF数据集对每个组件进行单独训练,实现了87.02%的总体准确率,N1期的F1分数为54.23%。

虽然基于深度学习的整体模型大大提高了睡眠分期的效率,但仍存在几个比较突出的问题:(1)由于不同睡眠阶段在整个睡眠过程中的比例严重不平衡,现有的睡眠EEG数据集中存在睡眠数据量不平衡问题,其中N2阶段占整个睡眠时间的45%~55%,N3阶段占20%,REM阶段占25%,N1阶段仅占2%~5%<sup>[16]</sup>。这种不平衡极大地影响了睡眠分期的准确性;(2)为了提高模型的表现力和泛化能力,很多学者通过增加网络层数来获得输入信号更有效的特征表达,但层级过多的神经网络可能会造成梯度消失;(3)在进行睡眠分期时,很多网络对于睡眠EEG时序特征及特异性特征深层提取不足。

基于此,笔者提出了一种基于睡眠 EEG 数据扩充的睡眠信号分期模型。整体原理框图如图 1 所示。

①采用改进的自适应合成采样技术(Adaptive Synthetic Sampling, ADASYN)算法,实现原始少样本类数据扩充,尽可能使数据达到类平衡;②使用深度 CNN 和 ResNet 组合提取局部特征,并保留足够的原

始数据信息,增强特征多样性和代表性;③利用带有多头自注意力层的 BiGRU 提取时序特征和特异性特征,该网络能够捕捉更多信息丰富的长期依赖关系,并对未表现出特异性或关键性特征的睡眠阶段给予同等关注。

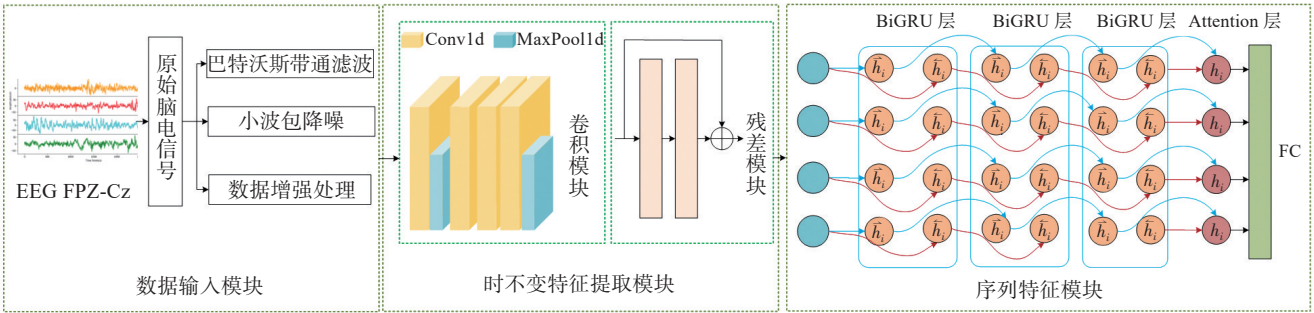


图 1 自动睡眠分期模型原理图

Figure 1 Schematic diagram of automatic sleep staging model

1 数据集和实验设置

1.1 数据集

Sleep-EDF Expanded 数据集<sup>[17]</sup>的这一子集包括 2 个研究:睡眠盒(Sleep Cassette, SC)研究对象为 25~34 岁受试者,旨在研究年龄和健康受试者的睡眠情况。睡眠遥测(Sleep Telemetry, ST)研究检测替马西洋对睡眠的影响。为了避免其他因素的影响,并遵循先前的研究,笔者在这项工作中使用了 SC 子集。Sleep-EDF-20 包含 20 位受试者连续两天和两晚的 PSG 记录,其中受试者 13 的第 2 个晚上的记录由于盒子或光盘的故障而丢失。Sleep-EDFx 数据集已扩展到包含 78 名年龄 25~101 岁的受试者,有 153 次整夜

PSG 睡眠记录。与 Sleep-EDF-20 类似,研究人员对每个受试者进行两个晚上的 PSG 记录。由于设备错误,受试者 13、36 和 52 各丢失了 1 条记录。睡眠专家根据 R&K 规则,通过视觉判断信号特征,将数据集中每个 30 s 历元标记为 8 个阶段,包括 Wake、S1、S2、S3、S4、REM、MOVEMENT、UNKNOWN。本文将 S3 和 S4 合并为 N3,MOVEMENT 和 UNKNOWN 阶段被移除,截取包含睡眠期前后 30 min 的睡眠 EEG。本实验根据 AASM 标准,合并了 S3 和 S4 阶段,将睡眠阶段划分为 Wake、N1、N2、N3 和 REM 五个阶段,并选取采样率为 100 Hz 的 Fpz-Cz 通道 EEG 数据。整体类别数据分布如表 1 所示。

表 1 手工分类标签类别数量分布

Table 1 Number distribution of manual classification label categories

数据集	受试者	采样率/Hz	不同睡眠阶段的样本量					总样本量
			Wake	N1	N2	N3	REM	
Sleep-EDF-20	$n=20$	100	10 197	2 804	17 799	5 703	7 717	44 220
Sleep-EDFx	$n=78$	100	69 824	21 522	69 132	13 039	25 835	199 352

1.2 数据预处理

1.2.1 数据降噪 为了消除不需要的眼球运动和工频干扰,使用频带为 0.5~40 Hz 的 4 阶巴特沃斯带通滤波器对睡眠 EEG 进行滤波处理。如 SC4001 有 841 个样本,每个样本 3 000 个时间点,滤波前后的 SC4001 受试者的第一个样本 EEG 如图 2a 和图 2b 所示。然后,利用小波包去噪<sup>[18]</sup>对睡眠 EEG 进行去噪。与传统的小波变换相比,该算法更加精确,能够对信号进

行更精细的分析,在信号表示方面具有更强的性能。本文采用 Daubechies 小波函数族中的 Db4 小波基函数,使用合适的数据长度和小波层数作为默认的分解层,并使用软阈值(Soft thresholding)函数对其进行修正,进一步提升去噪效果,从而实现降噪方案。去噪后的样本 EEG 如图 2c 所示。数据预处理后,每 30 s 将信号切片到相应的睡眠阶段,形成相应阶段的训练数据集进行训练。

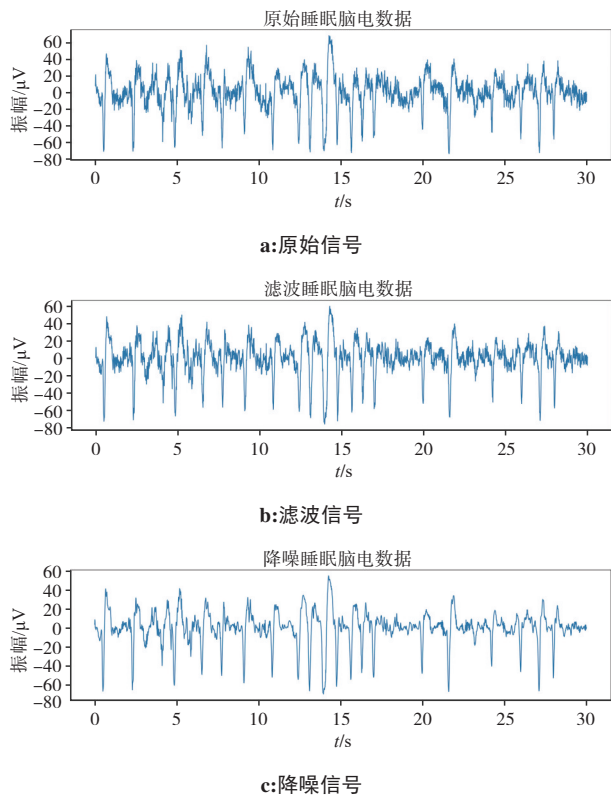


图2 原始数据与滤波降噪后的睡眠 EEG

Figure 2 Raw data and filtered noise-reduced sleep EEG signals

**1.2.2 数据增强** 为了解决数据集中样本类别不平衡问题,根据 AASM 标准,如表 1 所示的 5 种类型睡眠阶段的样本量比例, N1 阶段的样本量远小于其他阶段。为了提高睡眠分期的准确性,传统的合成少数类过采样方法 (Synthetic Minority Over-Sampling Technique, SMOTE) 通过插值少量样本生成新的合成样本。然而,这种方法生成的合成样本常常存在噪声和较高的相似性问题。因此,本文采用改进的 ADASYN 方法<sup>[19]</sup> 增强数据。相比于 SMOTE, ADASYN 在生成样本的过程中引入了自适应性,即根据样本的难度动态调整新样本的生成数量:难度越大,生成的样本数量就越多。具体方法如下:

(1) 计算生成的数据量  $G_s$ ,  $m_s$ ,  $m_l$  分别为类别少数数据量和类别多数数据量,  $m_s \leq m_l$ ,  $m_s + m_l = m$ ;  $\beta \in (0, 1)$ 。

$$G_s = (m_l - m_s)\beta \quad (1)$$

(2) 对于每个少数类样本,计算其  $K$  个邻居的欧几里得距离,并表示这些邻居中多数类样本的比例,其中  $K$  代表当前邻居的总数量,  $k$  则表示其中多数类样本的数量。

$$r_i = k/K \quad (2)$$

(3) 根据  $G$  计算生成少类别数据,根据式(4)生成样本,其中  $g$  为生成样本量,  $Z_i$  表示生成的样本,  $X_i$  表示当前少数样本,并且  $X_{z_i}$  表示  $X_i$  的  $k$  个邻居中的随机少数样本,  $\lambda \in (0, 1)$ 。

$$g = G \times r_i \quad (3)$$

$$Z_i = X_i + (X_{z_i} - X_i) \times \lambda \quad (4)$$

通过扩展少数类样本,模型能够更准确地学习和理解这些样本的特征,减轻多数类样本的主导作用,从而增强对少数类样本的识别与训练。由于每次迭代都需要计算每个样本的密度估计并基于这些值生成新的合成样本, ADASYN 方法增加了计算量,但整体训练时间较短,并且能显著提升模型性能。在处理不平衡数据集时,精准识别对于增强模型鲁棒性至关重要。因此,在实际应用中,少数类攻击往往具有极高的危害性,通过 ADASYN 扩展少数类样本能够更有效应对此类攻击,提升模型的分类表现。

### 1.3 实验环境与设置

在深度神经网络训练过程中, GPU 处理矩阵计算能力较强,所以采用 GPU 进行训练网络。本文模型训练实验基于计算机编程语言 Python 3.9.18 和深度学习框架 PyTorch2.1.2 下实现, GPU 为 NVIDIA GeForce RTX 4090D。

## 2 睡眠分期模型

### 2.1 CNN 与 ResNet

输入数据首先被分别送入 CNN 与 ResNet 这两个并行分支。CNN 主要由多层卷积、批标准化、ReLU 激活、池化和 Dropout 层组成,提取输入数据的高级特征。在卷积或池化之前,向输入张量添加零以维持或调整空间维度。ResNet 中通过  $1 \times 1$  卷积核大小的卷积层和批标准化层,然后进行 ReLU 激活和池化操作用于保留输入的原始特征信息。将 CNN 分支提取的复杂特征与 ResNet 保留的原始信息相结合,生成一个综合的特征表示。融合后的特征表示将被送入后续的 BiGRU 层、注意力层进行进一步的时序特征提取和分类任务。CNN 与 ResNet 的基础网络结构图如图 3 所示。

### 2.2 双向门控循环网络

RNN 的提出让神经网络具有了记忆时序信息前后特征的能力,但对长时序信号特征信息记忆力不足。随后提出的 GRU 是一种比 LSTM 网络更为简化的 RNN。它通过引入门控机制来调节信息的更新方式,其中更新门决定当前状态从历史状态中保留的信息量以及从候选状态中接收的新信息量,重置门控制前一时刻的隐藏状态对当前候选隐藏状态的影响程度,从而帮助模型动态选择需要保留或遗忘的历史信息<sup>[20]</sup>。

BiGRU 是一种递归神经网络,它能够有效捕捉序列中较远的依赖关系。通过双向性,可以同时考虑过去和未来的信息,提高模型对 EEG 数据的睡眠

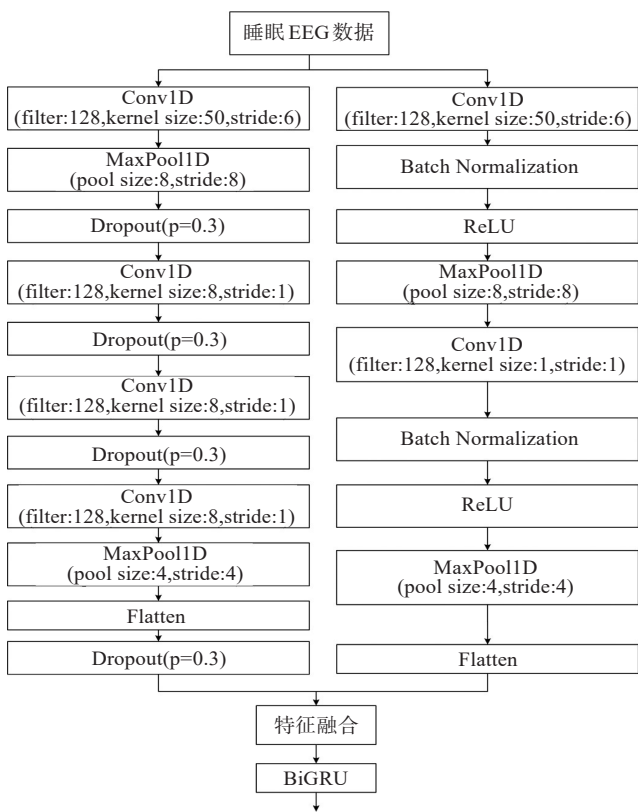


图3 基础CNN与ResNet结构  
Figure 3 Basic CNN and ResNet structures

阶段的时间序列动态变化的感知能力,从而高效提取信号特征和挖掘睡眠分期的前后相关性。BiGRU在 $t$ 时刻的输出由前向隐层 $\vec{h}$ 和后向隐层状态信息 $\overleftarrow{h}$ 加权求和得到:

$$\vec{h}_t = \text{GRU}(x_t, \vec{h}_{t-1}) \quad (5)$$

$$\overleftarrow{h}_t = \text{GRU}(x_t, \overleftarrow{h}_{t-1}) \quad (6)$$

$$h_t = w_t \vec{h}_t + v_t \overleftarrow{h}_t + b \quad (7)$$

其中, $x_t$ 为 $t$ 时刻的状态信息, $\vec{h}_{t-1}$ 和 $\overleftarrow{h}_{t-1}$ 分别为 $t-1$ 时刻保留的前向和后向状态特征, $w_t$ 和 $v_t$ 分别为前向隐层 $\vec{h}$ 和后向隐层状态信息 $\overleftarrow{h}$ 对应的权重, $b$ 为偏置项。BiGRU的单元结构如图4所示。

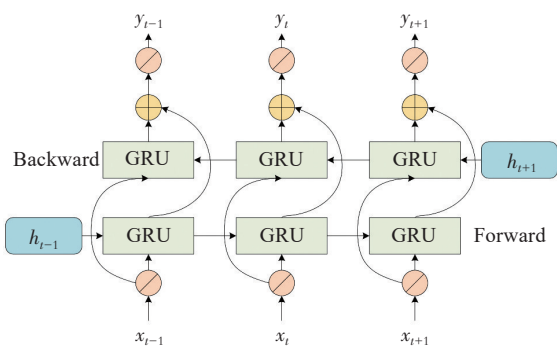


图4 双向门控循环网络结构图  
Figure 4 Structure diagram of bidirectional gated recurrent network

## 2.3 多头自注意力机制

多头自注意力机制(Multi-head Self Attention)<sup>[21]</sup>通过将输入的查询、键和值矩阵划分为多个头部,在每个头中独立计算注意力,再将各个头的输出进行拼接并进行线性变换,实现在不同子空间中同时捕获和融合多种交互信息,从而提升模型的表达能力。这使得模型能够灵活地对不同角度的输入信息进行加权,更好地处理睡眠 EEG 数据中的长时依赖性,有助于模型更精准地关注对预测结果有显著影响的时间节点。在本文中,引入8个头的自注意力机制,以更准确地提取全局信息,从而增强模型在睡眠阶段中提取特征时对输入序列的全局感知能力。

## 2.4 损失函数

为了找到使损失最小化的模型参数,更好地拟合训练数据并提升对测试数据的泛化能力,本文在数据增强的基础上,采用 Focal loss 损失函数<sup>[22]</sup>。该函数是对交叉熵损失函数的改进,能够通过调整权重分配优化类别不平衡时的分类效果。其主要目标是在处理大量容易分类的样本(即负样本)和少量难以分类的样本(即正样本)的情况下,增强模型对难分类样本的关注度。其公式为:

$$\text{FL}(p_t) = -\alpha_t (1 - p_t)^\gamma \log(p_t) \quad (8)$$

其中, $p_t$ 表示模型对正类样本的预测概率; $\alpha_t$ 为正负样本的平衡系数,用于平衡正负样本的权重;而 $\gamma$ 为一个调节因子,用于控制难易分类样本的权重,通过设定较高的 $\gamma$ 值,可以使模型更加关注那些难以分类的样本,减少容易分类样本的损失贡献。

## 3 实验结果与分析

### 3.1 评价指标

为了全面评价模型性能,本文对整体和每个睡眠阶段的类别指标进行评估。利用精确率(Precision rate, PR)、召回率(Recall, RE)和F1分数(F1 score, F1)评估每个睡眠阶段的分类性能;使用总体准确率(Accuracy)、Cohen's Kappa(Kappa)系数和宏平均F1值(Macro-averaged F1 score, MF1)<sup>[23-24]</sup>直观地理解和评估模型在整个数据集上的性能表现。

PR表示所预测到的某个睡眠阶段中正样本数据的比例:

$$\text{PR} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (9)$$

RE表示所有类别样本中某个睡眠阶段预测正确的样本数量所占的比例:

$$\text{RE} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (10)$$

F1表示精确度和召回率之间的平衡:

$$F1 = 2 \times \frac{PR \times RE}{PR + RE}$$

(11)

Accuracy 表示所有样本中正确预测的比例:

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN}$$

(12)

其中, TP 表示真实的正类样本, TN 表示真实的负类样本, FN 指错误分类为负类的正样本, FP 指错误分类为正类的负样本。

Cohen's Kappa 量化专家之间的一致程度, 常用于多分类性能的评价:

$$Kappa = \frac{P_o - P_e}{1 - P_e}$$

(13)

其中,  $P_o$  是每一种情况下, 正确分类样本与总体样本量的比值,  $P_e$  是预期与真实结果一致的概率, 其计算公式如下:

$$P_e = \frac{(t_1 \times p_1 + t_2 \times p_2 + \dots + t_i \times p_i + \dots + t_n \times p_n)}{N \times N}$$

(14)

其中,  $t_i$  表示每一类真实的样本数,  $p_i$  表示每一类预测的样本数,  $N$  代表总样本个数。

MF1 的公式如下:

$$MF1 = \frac{\sum_{i=1}^n F1_i}{n}$$

(15)

其中,  $F1_i$  表示  $i$  类的 F1 值,  $n$  表示类别。

3.2 模型评估与实验分析

3.2.1 训练设计 本文将数据集总样本 80% 的数据量划分为 8:2 的训练集和验证集, 数据集总样本剩余的 20% 作为测试集, 共有 5 类别输出。表 2 为本实验模型参数设置。

表2 实验模型参数  
Table 2 Experimental model parameters

参数名称	预设范围	最优参数
Epoch	[80,100,120,150]	100
Batch size	[16,32,64,128]	128
Warmup epochs	[5,10,20]	5
学习率	[0.001,0.0001,0.0005]	0.001
丢弃率	[0.2,0.3,0.5,0.7]	0.3
权重衰减	[0.01,0.1,0.001]	0.001
序列长度	[20,32,64]	20

利用数据集中 Fpz-Cz 通道的 EEG 信号所组成的训练集和验证集构建的模型。首先, 使用 Xavier 权重初始化, Xavier 初始化应用于卷积和线性层, 以保持所有层中的梯度比例大致相同; 其次, 通过多次训练对比发现, 使用带有权重衰减的自适应梯度方法对网络权重值进行更新优化, 有助于避免权重衰减对偏置参数的不必要影响; 然后, 在多次训练过程中, 网络仍然出现过拟合问题, 利用随机丢弃和梯度裁

剪方法以一定的机率随机地去掉网络中的神经元, 提升网络的泛化能力, 且使用 L2 正则化技术, 通过降低损失函数中的权重值减少模型复杂度, 防止可能出现的梯度不稳定和网络退化等问题; 最后, 采用 Warmup 预热学习率策略, 使得在训练的初期阶段学习率较低, 从而帮助模型逐步稳定, 并在后期维持较小的学习率, 以更精细地调整模型参数。通过合理的学习率调度策略, 可以避免模型陷入局部最优或者无法收敛的情况, 提高模型性能和稳定性, 提升模型训练效果。

3.3 实验结果

3.3.1 混淆矩阵 本文模型使用 Sleep-EDF-20 和 Sleep-EDFx 中 Fpz-Cz 通道的睡眠 EEG 数据。表 3~表 6 中, 行表示已知的人工标签, 列代表模型的预测结果, 对角线上的加粗数字表示两者预测一致的样本数量。在原始数据上训练集所得结果较好, 但是验证集和测试集相对偏低, 在利用数据增强技术后, 大大提高了所构建模型的泛化能力。表 3 和表 4 为原始睡眠 EEG 数据基于 CNN-BiGRU 自动睡眠模型得到的混淆矩阵, 表 5 和表 6 为数据增强处理后的数据集上基于 CNN-BiGRU 和 Multi-head Self Attention 自动睡眠分期模型得到的混淆矩阵。

表3 原始 Sleep-EDF-20 测试集数据在 CNN-BiGRU 模型下的性能指标和混淆矩阵

Table 3 Performance indicators and confusion matrix for CNN-BiGRU model on the original Sleep-EDF-20 dataset

标签	预测结果					性能指标/%		
	Wake	N1	N2	N3	REM	PR	RE	F1
Wake	<b>1 195</b>	105	18	0	33	94.4	88.7	91.5
N1	51	<b>226</b>	64	0	33	30.1	60.4	40.2
N2	15	273	<b>2 956</b>	77	253	89.9	82.7	86.2
N3	0	11	140	<b>777</b>	10	91.0	82.8	86.7
REM	5	139	110	0	<b>1 353</b>	80.4	84.2	82.3
Accuracy: 83.00%; MF1: 0.77; Kappa: 0.76								

加粗的数字表示模型分类正确的样本数

表4 原始 Sleep-EDFx 测试集数据在 CNN-BiGRU 模型下的性能指标和混淆矩阵

Table 4 Performance indicators and confusion matrix for CNN-BiGRU model on the original Sleep-EDFx dataset

标签	预测结果					性能指标/%		
	Wake	N1	N2	N3	REM	PR	RE	F1
Wake	<b>15 022</b>	673	150	19	137	95.4	93.9	94.7
N1	575	<b>1 940</b>	1 411	38	408	56.2	44.4	49.6
N2	88	560	<b>13 136</b>	402	419	83.8	89.9	86.7
N3	2	4	450	<b>2 152</b>	4	82.3	82.4	82.3
REM	54	276	533	4	<b>4 303</b>	81.6	83.2	82.4
Accuracy: 85.48%; MF1: 0.79; Kappa: 0.80								

加粗的数字表示模型分类正确的样本数

表5 类平衡Sleep-EDF-20测试集数据在CNN-BiGRU和Multi-head Self Attention模型下的性能指标和混淆矩阵

Table 5 Performance indicators and confusion matrix for the model incorporating CNN-BiGRU and Multi-head Self Attention on class-balanced Sleep-EDF-20 test set

标签	预测结果					性能指标/%		
	Wake	N1	N2	N3	REM	PR	RE	F1
Wake	<b>3 044</b>	180	59	0	17	93.5	92.2	92.8
N1	159	<b>2 861</b>	51	0	129	87.1	89.4	88.3
N2	54	157	<b>2 742</b>	140	167	89.5	84.1	86.7
N3	0	0	110	<b>2 030</b>	0	93.5	94.9	94.2
REM	0	85	100	0	<b>3 175</b>	91.0	94.5	92.7
Accuracy:90.77%; MF1:0.91; Kappa:0.88								

加粗的数字表示模型分类正确的样本数

表6 类平衡Sleep-EDFx测试集数据在CNN-BiGRU和Multi-head Self Attention模型下的性能指标和混淆矩阵

Table 6 Performance indicators and confusion matrix for the model incorporating CNN-BiGRU and Multi-head Self Attention on the class-balanced Sleep-EDFx test set

标签	预测结果					性能指标/%		
	Wake	N1	N2	N3	REM	PR	RE	F1
Wake	<b>11 637</b>	502	170	55	236	90.4	92.4	91.4
N1	678	<b>6 723</b>	1 484	40	655	77.2	70.2	73.5
N2	274	1 032	<b>10 913</b>	1 261	600	79.7	77.5	78.6
N3	0	20	322	<b>10 458</b>	0	87.8	96.8	92.1
REM	278	435	810	99	<b>8 858</b>	85.6	84.5	85.1
Accuracy:84.44%; MF1:0.84; Kappa:0.80								

加粗的数字表示模型分类正确的样本数

通过对表3和表4的数据分析可以发现,虽然CNN-BiGRU模型在自动睡眠分期任务中表现出较好的整体准确率,但其对样本量较少的N1阶段识别性能明显不足。具体而言,该模型在Sleep-EDF-20数据集上N1阶段的PR仅为30.1%,在Sleep-EDFx数据集上也仅达到56.2%。这一结果表明,传统模型在处理类别不平衡数据时存在明显局限性。

对比表5和表6的实验结果可以看出,引入Multi-head Self Attention机制并结合CNN-BiGRU的改进模型显著提升了分类性能。特别是在采用ADASYN数据增强方法进行类别平衡处理后,模型性能得到全面提升:在Sleep-EDF-20数据集上Accuracy达到90.77%;在Sleep-EDFx数据集上,MF1和Kappa系数分别提升至0.84和0.80。值得注意的是,N1期的PR和RE均有显著提高,同时其他睡眠分期的分类效果也获得不同程度的改善。这些实验结果充分证明,改进的ADASYN数据增强方法能有效缓解睡眠数据中的类别不平衡问题,从而全面提升模型在各个睡眠分期的分类性能。特别是在提升少

数类N1阶段样本识别能力方面,该方法展现出显著优势,为自动睡眠分期研究提供了新的技术思路。

**3.3.2 睡眠时相序列图** 构建自动睡眠分期的目的是为临床诊断提供高效的辅助判别工具,时相序列图能够直观展示各个睡眠状态随时间的变化情况。为更清晰地展示本文模型的预测效果,随机选取Sleep-EDFx数据集中某受试者的整晚睡眠数据,并将专家与本文模型的预测结果进行对比,如图5、图6和图7所示,横轴表示时间,纵轴从下至上代表不同的睡眠阶段。由于睡眠是一个连续过程,相邻阶段之间的特征具有较高相似性。从序列图可以看出,模型所得到的睡眠状态变化趋势整体上与人工标注基本一致,但该模型在区分容易混淆的N1阶段时表现出更高的准确率,可以为临床诊断提供一定的辅助判断。

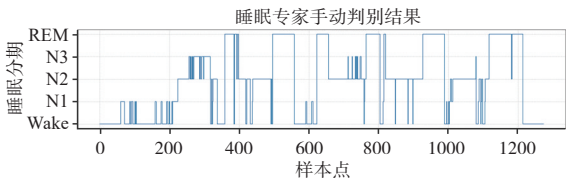


图5 临床专家手动分期结果  
Figure 5 Manual staging results of clinical experts

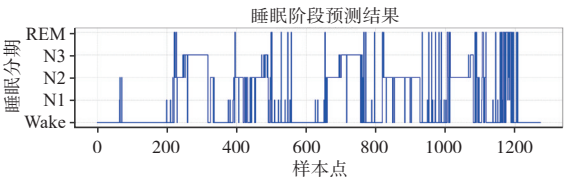


图6 CNN-BiGRU模型自动分期结果  
Figure 6 Automatic staging results of CNN-BiGRU model

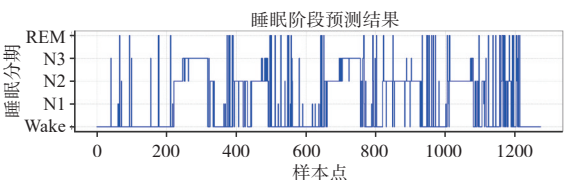


图7 CNN-BiGRU和Multi-head Self Attention模型自动分期结果  
Figure 7 Automatic staging results of the model incorporating CNN-BiGRU and Multi-head Self Attention

**3.3.3 方法比较** 为进一步验证CNN-BiGRU和Multi-head Self Attention结合起来的模型的有效性,表7展示相同数据集下和相同EEG通道的部分文献中自动睡眠分期判别结果比较,相比其他自动睡眠分期网络,本文模型整体准确率有5%~8%的提升,Kappa系数有6%的提升。

表7 基于CNN-BiGRU和Multi-head Self Attention的自动睡眠分期模型和其他分类方法的比较

Table 7 Comparison of the automatic sleep staging model based on CNN-BiGRU and Multi-head Self Attention with other classification methods

数据集	受试者	模型方法	每个类别的准确率/%					总体性能		
			Wake	N1	N2	N3	REM	Accuracy/%	MF1/%	Kappa
Sleep-EDF-20	n=20	DeepSleepNet <sup>[25]</sup>	84.7	46.6	85.9	84.8	82.4	82.0	76.9	0.76
		SleepEEGNet <sup>[26]</sup>	89.2	52.2	86.8	85.1	85.0	84.3	79.6	0.75
		AttnSleepNet <sup>[27]</sup>	89.7	42.6	88.8	90.2	79.0	84.4	78.1	0.79
		3CNN-BiGRU <sup>[28]</sup>	89.0	36.0	85.0	90.0	94.0	83.5	77.3	0.77
		CNN-BiLSTM-Attention <sup>[29]</sup>	90.0	56.0	92.5	80.5	85.9	85.5	82.1	0.82
		本文方法	93.5	87.1	89.5	93.5	91.0	90.8	91.0	0.88
Sleep-EDFx	n=78	DeepSleepNet <sup>[25]</sup>	90.9	45.0	79.2	72.7	71.1	77.8	71.8	0.70
		SleepEEGNet <sup>[26]</sup>	89.8	42.1	75.2	70.4	70.6	74.2	69.6	0.66
		AttnSleepNet <sup>[27]</sup>	92.0	42.0	85.0	82.1	74.2	81.3	75.1	0.74
		1D-ResNet-SE-LSTM <sup>[13]</sup>	94.9	59.1	86.5	87.8	86.2	86.4	81.9	0.81
		CNN-BiGRU-Attention <sup>[30]</sup>	83.0	57.1	81.2	68.7	90.2	84.0	84.0	0.77
		本文方法	90.4	77.2	79.7	87.8	85.6	84.4	84.0	0.80

4 总 结

本研究提出一种基于数据增强的自动睡眠分期模型,旨在提升少样本睡眠阶段的分类精度。该模型包含3个核心模块:(1)数据预处理与类平衡:采用巴特沃斯带通滤波器进行频段筛选,结合小波包变换对原始EEG信号进行降噪处理;针对N1等少样本类别,提出改进的ADASYN算法,对少样本类数据进行扩充,实现类别间样本的均衡化。(2)特征融合网络:构建CNN与ResNet的并行网络,前者利用局部感受野获取局部特征细节;后者通过残差连接保留原始有用的信息,在此基础上,引入BiGRU学习较长时间的时序依赖,并通过Multi-head Self Attention建立跨时间片的全局上下文关联,形成时空特征联合表征。(3)优化训练:进行超参数调优,设置Warmup预热学习率与Focal loss损失函数,确保模型稳定性。由表7的对比结果可以得出,基于CNN-BiGRU和Multi-head Self Attention自动睡眠分期模型在Sleep-EDF-20数据集上相比其他方法的Accuracy有4%~8%的提升,在N1阶段的PR有31.0%~51.1%的提升;同样,在Sleep-EDFx数据集上相比其他方法的MF1有一定的提升,在N1阶段的PR有20.1%~35.2%的提升,证实本文方法能有效解决类不平衡问题并提升总体分期精度,为便携式家庭睡眠监测系统的开发奠定了一定的基础。

然而,该模型仍存在一些不足。首先,在数据增强方面,当前方法难以精确生成与真实样本分布完全一致的合成样本,导致分类时可能出现偏差。特别是在处理睡眠过渡阶段(如N1期与其他阶段的转换)时,模型的分类性能仍有待提升。未来研究可探

索更先进的样本生成方法,如生成对抗网络(GANs)及其改进模型(如Wasserstein GAN、Conditional GAN等),以生成更高质量、更符合真实数据分布的合成样本,从而进一步提升模型的分类鲁棒性。其次,当前模型仅基于单通道EEG信号进行睡眠分期,而睡眠状态的判别实际上依赖于多模态生理信号的协同分析。例如,EOG信号可有效反映REM睡眠特征,EMG活动能辅助区分Wake与其他睡眠阶段,而ECG和呼吸节律的变化也与不同睡眠阶段密切相关。因此,未来工作应考虑融合EEG、EOG、EMG、ECG等多模态信号,并结合多通道、多视图的数据,以更全面地捕捉睡眠-觉醒转换的动态特征。最后,为进一步验证模型的泛化能力,可结合公开数据集和本地采集的多模态睡眠数据,系统评估模型在跨受试者、跨模态场景下的性能。通过多模态融合与迁移学习相结合的策略,有望显著提升自动睡眠分期系统的鲁棒性和临床适用性,为睡眠障碍的精准诊断与个性化干预提供更可靠的技术支持。

【参考文献】

[1] Ebrahim K, Babak AM. Automatic sleep stage classification using temporal convolutional neural network and new data augmentation technique from raw single-channel EEG[J]. Comput Methods Programs Biomed, 2021, 204: 106063.

[2] Phan H, Mikkelsen K. Automatic sleep staging of EEG signals: recent development, challenges, and future directions[J]. Physiol Meas, 2022, 43(4): 04TR01.

[3] 唐伟顺. 基于深度学习的双通道自动睡眠分期算法及其迁移与应用[D]. 广州: 华南理工大学, 2021.

Tang WS. A deep-learning based dual-channel automatic sleep staging algorithm and its transfer and application[D]. Guangzhou: South China University of Technology, 2021.

[4] Moeller AL, Perslev M, Paulsruud C, et al. Artificial intelligence or sleep experts: Comparing polysomnographic sleep staging in children and adolescents[J]. Sleep, 2025: zsaf053.

- [5] Giri EP, Arymurthy AM, Fanany MI, et al. Sleep stages classification using shallow classifiers[C]//2015 International Conference on Advanced Computer Science and Information Systems (ICACSIS). Piscataway, NJ, USA: IEEE, 2015: 297-301.
- [6] Abdulla S, Diyykh M, Laft RL, et al. Sleep EEG signal analysis based on correlation graph similarity coupled with an ensemble extreme machine learning algorithm[J]. Expert Syst Appl, 2019, 138: 112790.
- [7] Wolpert EA. A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects[J]. Arch Gen Psychiatry, 1969, 20(2): 246-247.
- [8] Berry RB, Budhiraja R, Gottlieb DJ, et al. Rules for scoring respiratory events in sleep: update of the 2007 AASM Manual for the Scoring of Sleep and Associated Events. Deliberations of the Sleep Apnea Definitions Task Force of the American Academy of Sleep Medicine[J]. J Clin Sleep Med, 2012, 8(5): 597-619.
- [9] 金峥, 贾克斌. 基于生理电信号的自动睡眠分期算法综述[J]. 北京工业大学学报, 2025, 51(4): 435-451.  
Jin Z, Jia KB. Review of automatic sleep stage classification algorithms based on physiological signals [J]. Journal of Beijing University of Technology, 2025, 51(4): 435-451.
- [10] Zaman A, Kumar S, Shatabda S, et al. SleepBoost: a multi-level tree-based ensemble model for automatic sleep stage classification [J]. Med Biol Eng Comput, 2024, 62(9): 2769-2783.
- [11] Satapathy SK, Brahma B, Panda B, et al. Machine learning-empowered sleep staging classification using multi-modality signals[J]. BMC Med Inform Decis Mak, 2024, 24(1): 119.
- [12] Li QY, Wang B, Jin J, et al. Comparison of CNN-uni-LSTM and CNN-Bi-LSTM based on single-channel EEG for sleep staging[C]//2020 5th International Conference on Intelligent Informatics and Biomedical Sciences (ICIIBMS). Piscataway, NJ, USA: IEEE, 2020: 76-80.
- [13] Li WM, Gao JH. Automatic sleep staging by a hybrid model based on deep 1D-ResNet-SE and LSTM with single-channel raw EEG signals[J]. PeerJ Comput Sci, 2023, 9: e1561.
- [14] Liu CY, Yin YF, Sun YH, et al. Multi-scale ResNet and BiGRU automatic sleep staging based on attention mechanism[J]. PLoS One, 2022, 17(6): e0269500.
- [15] Jirakittayakorn N, Wongsawat Y, Mitirattanakul S. ZleepAnlystNet: a novel deep learning model for automatic sleep stage scoring based on single-channel raw EEG data using separating training[J]. Sci Rep, 2024, 14(1): 9859.
- [16] Fan JH, Sun CL, Chen C, et al. EEG data augmentation: towards class imbalance problem in sleep staging tasks[J]. J Neural Eng, 2020, 17(5): 056017.
- [17] Ghimatgar H, Kazemi K, Helfrroush SM, et al. An automatic single-channel EEG-based sleep stage scoring method based on hidden markov model[J]. J Neurosci Methods, 2019, 324: 108320.
- [18] 孙晓娟, 王利. 基于 CEEMD 小波包算法的降噪方法研究[J]. 计算机与现代化, 2020(9): 73-76.  
Sun XJ, Wang L. A denoising method based on CEEMD wavelet packet[J]. Computer and Modernization, 2020(9): 73-76.
- [19] Aymaz S. Boosting medical diagnostics with a novel gradient-based sample selection method[J]. Comput Biol Med, 2024, 182: 109165.
- [20] 胡凯蕾, 陈景霞, 张鹏伟, 等. 用于睡眠精准分期的多模态生理时频特征提取网络[J]. 生物医学工程学杂志, 2024, 41(1): 26-33.  
Hu KL, Chen JX, Zhang PW, et al. Multi-modal physiological time-frequency feature extraction network for accurate sleep stage classification[J]. Journal of Biomedical Engineering, 2024, 41(1): 26-33.
- [21] Xu C, Gao Y. Multi-modal transformer with multi-head attention for emotion recognition[C]//2023 IEEE International Conference on Sensors, Electronics and Computer Engineering (ICSECE). Jinzhou, China. IEEE, 2023: 826-831.
- [22] Lin TY, Goyal P, Girshick R, et al. Focal loss for dense object detection[J]. IEEE Trans Pattern Anal Mach Intell, 2020, 42(2): 318-327.
- [23] 唐万, 胡俊, 张晖, 等. Kappa 系数: 一种衡量评估者间一致性的常用方法(英文)[J]. 上海精神医学, 2015, 27(1): 62-67.  
Tang W, Hu J, Zhang H, et al. Kappa coefficient: a common method to measure inter-rater agreement[J]. Shanghai Archives of Psychiatry, 2015, 27(1): 62-67.
- [24] Ying S, Li P, Chen J, et al. An EEG-based single-channel dual-stream automatic sleep staging network with transfer learning[J]. Appl Soft Computing, 2025, 170: 112722.
- [25] Supratak A, Dong H, Wu C, et al. DeepSleepNet: a model for automatic sleep stage scoring based on raw single-channel EEG[J]. IEEE Trans Neural Syst Rehabil Eng, 2017, 25(11): 1998-2008.
- [26] Mousavi S, Afghah F, Acharya UR. SleepEEGNet: automated sleep stage scoring with sequence to sequence deep learning approach [J]. PLoS One, 2019, 14(5): e0216456.
- [27] Eldele E, Chen ZH, Liu CY, et al. An attention-based deep learning approach for sleep stage classification with single-channel EEG[J]. IEEE Trans Neural Syst Rehabil Eng, 2021, 29: 809-818.
- [28] 唐洁, 文元美. 基于 3CNN-BiGRU 的睡眠自动分期研究[J]. 计算机与现代化, 2022(2): 120-126.  
Tang J, Wen YM. Automatic sleep staging based on 3 CNN-BiGRU [J]. Computer and Modernization, 2022(2): 120-126.
- [29] 曹科研, 王莹莹, 陶杭波. 基于自注意力机制与双向 LSTM 的睡眠分期模型[J]. 软件导刊, 2024, 23(5): 24-32.  
Cao KY, Wang YY, Tao HB. A sleep staging model based on self-attention mechanism and bi-directional LSTM[J]. Software Guide, 2024, 23(5): 24-32.
- [30] 刘颖, 何长乐, 苑成梅, 等. 基于注意力机制与双向门控循环单元的多导睡眠图睡眠阶段分期方法研究[J]. 生物医学工程学杂志, 2023, 40(1): 35-43.  
Liu Y, He CL, Yuan CM, et al. Study on the method of polysomnography sleep stage staging based on attention mechanism and bidirectional gate recurrent unit[J]. Journal of Biomedical Engineering, 2023, 40(1): 35-43.

(编辑: 黄开颜)