

# 基于多视图与注意力机制的睡眠脑电分期<sup>\*</sup>

李兰亭<sup>1</sup> 苗敏敏<sup>1,2</sup>

(1. 湖州师范学院信息工程学院 湖州 313000; 2. 浙江省现代农业资源智慧管理与应用研究重点实验室 湖州 313000)

**摘要:**为了更全面地对睡眠脑电进行特征提取,提出一种基于多视图与注意力机制的睡眠脑电分期方法。首先针对原始睡眠脑电信号构造时域和时频域两类视图数据;然后设计融合注意力机制的混合神经网络对多视图数据进行表征学习;接着通过双向长短时记忆(bi-directional long short-term memory, BiLSTM)网络进一步学习睡眠阶段之间的转换规则;最后使用Softmax函数进行睡眠分期,并利用类别加权损失函数解决睡眠数据类别不均衡的问题。实验使用Sleep-EDF数据库中前20名受试者的单通道脑电信号并采用20折交叉验证对模型进行性能评估,睡眠分期准确率达到83.7%,宏平均 $F_1$ 值达到79.0%,Cohen's Kappa系数达到0.78。与现有方法相比,算法性能提升明显,证明了所提方法的有效性。

**关键词:**睡眠分期;多视图;注意力机制;双向长短时记忆网络;类别加权损失函数

中图分类号: R318 文献标识码:A 国家标准学科分类代码: 520.2040

## Sleep EEG staging based on multi-view and attention mechanism

Li Lanting<sup>1</sup> Miao Minmin<sup>1,2</sup>

(1. School of Information Engineering, Huzhou University, Huzhou 313000, China; 2. Zhejiang Province Key Laboratory of Smart Management and Application of Modern Agricultural Resources, Huzhou 313000, China)

**Abstract:** In order to extract features of sleep EEG more comprehensively, a sleep EEG staging method based on multi-view and attention mechanism is proposed. First, two types of view data, namely time domain and time-frequency domain, are constructed based on the original sleep EEG signal. Then, a hybrid neural network with attention mechanism is designed to perform representation learning on multi-view data. Next, the transition rules between sleep stages are further learned through a bidirectional long short-term memory network. Finally, the Softmax function is used for sleep staging, and the class weighted loss function is utilized to solve the problem of unbalanced sleep data categories. In this experiment, the single-channel EEG signals of the first 20 subjects in the Sleep-EDF database are used, and 20-fold cross-validation is adopted to evaluate the performance of the model. The accuracy of sleep staging reaches 83.7%, the macro- $F_1$ -score ( $MF_1$ ) reaches 79.0%, and the Cohen's Kappa coefficient reaches 0.78. Compared with the existing methods, the performance of the algorithm in this paper is significantly improved, which proves the effectiveness of the proposed method.

**Keywords:** sleep staging; multi-view; attention mechanism; bidirectional long short-term memory networks; class weighted loss function

## 0 引言

睡眠占据人一生中大约1/3的时间,睡眠的好坏直接影响人们的身体和心理健康<sup>[1]</sup>。良好的睡眠质量是机体保持健康的基础,有助于提高人们的免疫力和工作效

率<sup>[2]</sup>。随着现代人生活压力的增大,长期睡眠不足会引发焦虑、记忆力衰退和抑郁等症<sup>[3]</sup>。睡眠分期作为有效评估睡眠质量和诊断睡眠相关疾病的基础,具有重要的研究意义<sup>[4]</sup>。

传统的人工睡眠分期需要睡眠专家根据睡眠分期准

收稿日期:2023-08-04

\*基金项目:国家自然科学基金青年科学基金(62101189)、浙江省自然科学基金(LTGC23F010001)项目资助

则将获取的多导睡眠图分为不同的睡眠阶段<sup>[5]</sup>。然而,整晚的睡眠脑电数据量大,这种人工分期方法耗时费力,评估结果也易受到专家主观因素的影响<sup>[6]</sup>。随着人工智能技术的发展,自动睡眠分期引起了众多学者的关注。早期的自动睡眠分期方法需要经验丰富的专家手动提取特征,这些特征通常使用时域分析、频域分析、时频域分析和非线性分析法来进行提取<sup>[7]</sup>,并使用随机森林、支持向量机和决策树等分类算法进行分期,这种方法存在效率低、泛化性不足等缺点<sup>[8]</sup>。

近年来,深度学习技术开始被用于睡眠脑电分期领域,通过神经网络以端到端的方式自动提取高级抽象语义特征,避免了手动提取特征的缺陷<sup>[9]</sup>。Supratak 等<sup>[5]</sup>提出了 DeepSleepNet 深度学习模型,利用卷积神经网络(convolutional neural networks,CNN)提取睡眠特征,并使用双向长短记忆(bi-directional long short-term memory,BiLSTM)学习睡眠阶段之间的转换规则。Eldele 等<sup>[10]</sup>提出了 AttnSleep 深度学习模型,加入多头注意力机制学习特征之间的时间依赖关系。Khalili 等<sup>[11]</sup>采用时间卷积神经网络提取特征,并通过条件随机场层捕获睡眠状态转换规则。金峰等<sup>[12]</sup>提出了一种混合注意力时序网络,采用循环神经网络取代传统的卷积神经网络提取时序特征,并使用注意力机制学习时序上下文特征。陈玲玲等<sup>[8]</sup>采用残差收缩网络提取时不变特征,并通过 BiLSTM 提取时序特征。上述睡眠分期方法大多采用单一视图特征,无法全面描述睡眠脑电特性。

多视图是指对同一对象从不同的角度进行描述,为了对脑电信号进行更全面地表征,本文提出一种基于多视图与注意力机制的睡眠脑电分期方法。根据原始睡眠脑电信号构造时域和时频域两类视图数据,并构建两个独立的

深度神经网络分别对各视图进行表征学习。针对时域视图,利用 CNN 和残差压缩聚合(squeeze and excitation,SE)模块对时序信号进行特征提取和自适应特征校准,挖掘类间区分度高的特征。需要注意的是,CNN 具有局部敏感性,能够提取高层语义特征,但缺乏对全局信息的有效学习,视觉转换器(vision transformer,ViT)模型可以通过注意力机制获得全局上下文信息。因此,针对睡眠脑电时频域视图,本文构建 CNN 和 ViT 并行网络结构,联合提取脑电时频图的局部—全局特征。然后将两类视图提取的特征进行组合,再利用 BiLSTM 对脑电长序列信号进行双向学习,挖掘相邻睡眠阶段间的关联信息,提高分类性能。此外,本文使用类别加权损失函数解决睡眠数据类别不均衡的问题,有效提高了小样本类别的分类精度。

## 1 模型框架

本文模型由 3 部分组成。第 1 部分是多视图特征提取,由时序特征提取模块和时频图特征提取模块两个独立的模块组成。时序特征提取模块是采用多尺度 CNN 提取脑电时序信号的时间和频率特征,再加入残差 SE 块,自适应地为每个特征分配权重,挖掘类间区分度高的特征。时频图特征提取模块是联合 CNN 和 ViT 模型提取脑电时频图的局部和全局特征。第 2 部分是特征融合层,将两类视图提取的特征进行组合。第 3 部分是睡眠阶段转换规则与分期,利用 BiLSTM 进一步挖掘相邻睡眠阶段间的转换规则,再使用 Softmax 函数进行睡眠分期,整体模型框架如图 1 所示。

### 1.1 构造多视图数据

本文主要从时域和时频域两个角度构造多视图数据,原始的脑电信号作为时域视图数据,再利用短时傅里

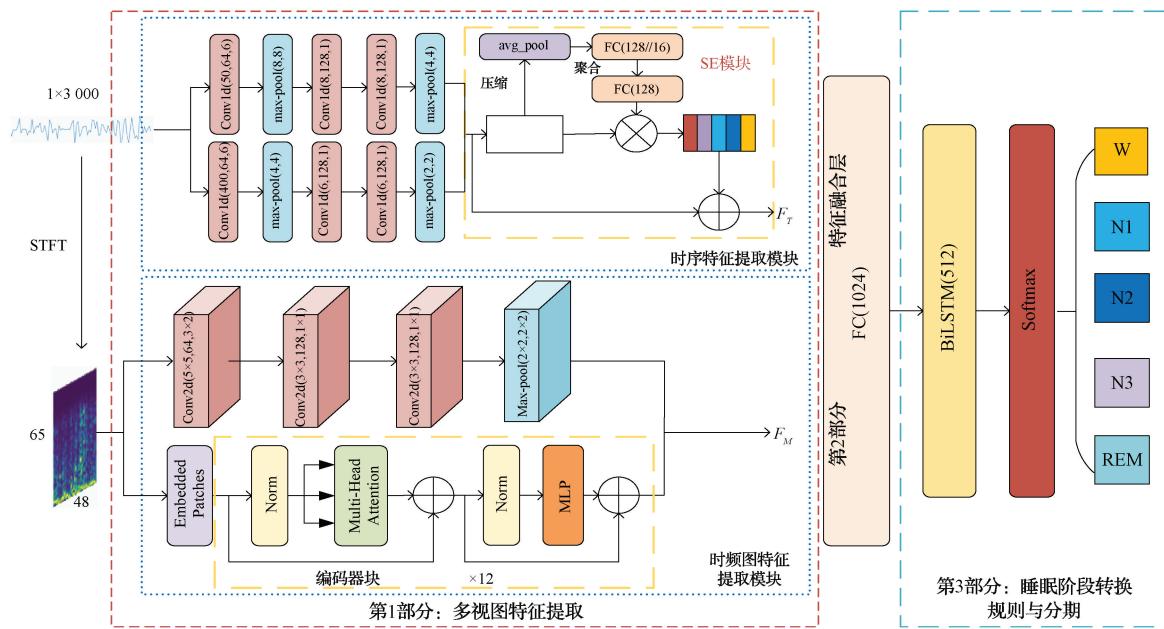


图 1 整体模型框架

叶变换将时域信号转换为脑电时频图,作为时频域视图数据。

### 1) 时序信号

将脑电信号以 30 s 为一个数据样本进行划分,并使用 5 阶巴特沃斯滤波器进行 0.2~35 Hz 带通滤波,再进行 Z-score 标准化处理,得到时序信号数据集 T。

### 2) 时频图

短时傅里叶变换 (short-time Fourier transform, STFT) 是一种时频分析法,其基本思想是将信号与窗函数进行相乘,再进行傅里叶变换,通过窗函数在时间轴上滑动,计算各个不同时间段的频谱得到时频图<sup>[18]</sup>,基本计算

公式如下:

$$S_{TFTX}(t, \omega) = \int_{-\infty}^{+\infty} x(t)h(t-\omega)e^{-j\omega t} dt \quad (1)$$

式中:  $x(t)$  为时域信号;  $h(t-\omega)$  为窗函数。

脑电信号是由不同频率范围的节律波组成,各频段内的信号幅值在不同睡眠阶段会产生相应变化。时频图能更好地反映脑电信号的时频域信息,所以本文使用 STFT,通过长度为 128 和 50% 重叠的滑动窗口对滤波后的每个样本进行分窗,并计算每个窗口内幅值的平方再进行归一化,构造  $65 \times 48$  的特征矩阵,得到时频图数据集 M,不同睡眠阶段的时频图如图 2 所示。

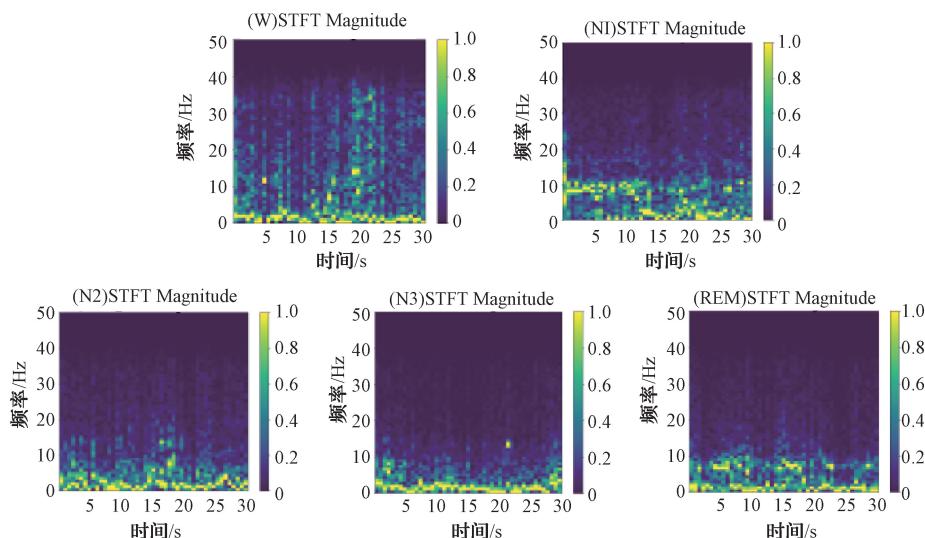


图 2 不同睡眠阶段的时频图

## 1.2 多视图特征提取

多视图特征提取如图 1 所示(第 1 部分),网络参数为  $[K, C, S]$ ,其中 K 表示卷积核的大小或池化尺度,C 表示通道数目,S 表示步长。多视图特征提取由时序特征提取模块和时频图特征提取模块组成。时序特征提取模块是采用多尺度 CNN 和残差 SE 块提取脑电时序信号特征,并挖掘类间区分度高的特征。时频图特征提取模块是联合 CNN 和 ViT 模型提取脑电时频图的局部-全局特征。

### 1) 时序特征提取模块

时序特征提取模块是针对时域视图构建的网络,由并行的两个卷积神经网络和残差 SE 块组成。并行的卷积网络具有相同的结构,由 3 个卷积层和两个最大池化层组成,每个卷积层后经过 Leaky ReLU 激活函数。两个卷积网络使用大小不同的卷积核,研究表明,较小尺度的卷积核能更好地学习时域信息,较大尺度的卷积核能更好地学习频域信息<sup>[5]</sup>。所以,本文使用不同大小的卷积核来提取脑电信号的时间和频率特征,然后将提取的时间和频率特征进行组合,通过 SE 块自适应地为每个特征分配权重,增强重要特征<sup>[10,14]</sup>,最后使用快捷连接将原始特征与 SE 模块增强后的特征相结合,得到该模块最终输出。

SE 块的原理如图 1 所示(SE 模块),设输入到 SE 块的特征 F 的维度为  $(N \times d)$ ,其中 N 为特征数量,d 为特征长度。首先采用全局平均值池化,将特征 F 压缩为一维向量  $S = \{S_1, S_2, \dots, S_N\}$ ,然后通过两个完全连接层和 Sigmoid 函数将 S 转换为权重 e,最后通过特征 F 与权重 e 相乘,得到增强后的特征。

使用的 Leaky ReLU 激活函数,定义如下<sup>[15]</sup>:

$$\text{leakyReLU}(x) = \begin{cases} x, & x \geq 0 \\ \alpha x, & x < 0 \end{cases} \quad (2)$$

式中: x 为 Leaky ReLU 激活函数的输入;  $\alpha$  为可调参数。

将时序信号数据集 T 输入到时序特征提取模块中的过程表述如下:

$$f_i = \text{CNN}_s(T) \quad (3)$$

$$f_j = \text{CNN}_t(T) \quad (4)$$

$$F_1 = f_i \parallel f_j \quad (5)$$

$$F_2 = \text{SE}(F_1) \quad (6)$$

$$F_T = F_1 + F_2 \quad (7)$$

式中:  $\text{CNN}_s$  和  $\text{CNN}_t$  分别表示较大卷积核和较小卷积核的卷积网络;  $f_i$  和  $f_j$  分别表示提取的频率和时间特征;  $\parallel$  表示连接操作;  $F_1$  为时间特征和频率特征的拼接;  $\text{SE}$

为压缩聚合模块;  $F_2$  为 SE 模块增强后的特征;  $F_T$  为时序特征提取模块提取的特征。

### 2) 时频图特征提取模块

时频图特征提取模块是针对时频域视图构建的网络, 将 CNN 与 ViT 模型并行, 联合学习脑电时频图的局部-全局信息。CNN 由 3 个二维卷积层和一个最大池化层组成, 每个卷积层后经过 Leaky ReLU 激活函数。ViT 模型主要由 Embedding 层和 Transformer 编码器层组成。

#### (1) Embedding 层

首先将  $65 \times 48$  的二维时频图划分为 30 个  $13 \times 8$  的图像块, 然后通过线性映射将每个图像块转换为一维向量, 再添加一个可学习的类别变量  $X_{class}$ , 用于学习时频图的全局信息<sup>[16-17]</sup>, 最后为每个图像块加上位置编码, 保留位置信息, 作为编码器的输入。

#### (2) Transformer 编码器

Transformer 编码器是由编码器块堆叠而成, 结构如图 1 所示(编码器块), 主要包括多头注意力机制(multi-head attention, MSA)、多层次感知机(multilayer perceptron, MLP)、残差连接和归一化层。

自注意力机制是将输入序列生成查询(query, Q)、键(key, K)和值(value, V)3 个矩阵, 进行缩放点积注意力操作, 得到自注意力权重<sup>[18]</sup>, 计算过程如下:

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (8)$$

式中:  $d_k$  为  $K$  矩阵的维度。

MSA 是将多个单头注意力机制的输出进行拼接, 从不同的角度学习序列信息, 使模型为不同的位置特征分配不同的权重。本文采用多头注意力层的头数为 8 个。

MLP 是由两个全连接层、高斯误差线性单元(Gaussian error linear unit, GeLU)激活函数和 Dropout 层组成, 通过两个全连接层先升维后降维的方法进行信息交互。

本文使用 ViT 模型经过 12 层编码器块对脑电时频图进行特征提取, 不仅包含  $X_{class}$  学习的全局特征, 也包含每个图像块的局部特征, 再与 CNN 提取的高层局部特征进行组合, 得到脑电时频图局部-全局特征。ViT 模型的过程表述如下:

$$Z_t^1 = \text{MSA}(\text{LN}(Z_{t-1})) + Z_{t-1} \quad (9)$$

$$Z_t = \text{MLP}(Z_t^1) + Z_t^1 \quad (10)$$

式中: LN 为归一化层;  $Z_{t-1}$  为上一层编码器块的输出;  $Z_t^1$  为模型中间值;  $Z_t$  为本层编码器块的输出。

将时频图数据集  $M$  输入到时频图特征提取模块中的过程表述如下:

$$F_3 = \text{CNN}_r(M) \quad (11)$$

$$F_4 = \text{ViT}(M) \quad (12)$$

$$F_M = \text{Flatten}(F_3) \parallel \text{Flatten}(F_4) \quad (13)$$

式中:  $\text{CNN}_r$  为二维卷积网络;  $F_3$  为卷积网络的输出;  $F_4$  为 ViT 模型的输出;  $\text{Flatten}$  为展平层;  $F_M$  为时频图特征

提取模块提取的特征。

### 1.3 特征融合层

特征融合层旨在融合多视图特征提取模块提取的特征, 利用全连接层组合提取的高级特征, 再经过 Leaky ReLU 激活函数, 融合过程表述如下:

$$F_s = \text{leakyReLU}(\text{FC}(\text{Flatten}(F_T) \parallel F_M)) \quad (14)$$

式中:  $\parallel$  表示连接操作; FC 为全连接层;  $F_s$  为融合后的特征。

### 1.4 睡眠阶段转换规则与分期

睡眠过程呈周期性变化, 各睡眠阶段前后具有强时序性和关联性, BiLSTM 网络可以挖掘长序列信号间的前后依赖关系<sup>[19-20]</sup>。所以本文使用 BiLSTM 通过两个长短时记忆网络(long short-term memory, LSTM)独立地处理前向和后向长序列脑电睡眠信息, 更好地学习各睡眠阶段间的转换规则, 最后使用 Softmax 函数进行睡眠分期。

睡眠阶段转换规则与分期的网络结构如图 3 所示(第 3 部分), 将融合后的特征序列输入到双向长短时记忆网络中, 再使用 Softmax 函数进行睡眠分期。睡眠阶段转换规则与分期原理如图 3 所示。

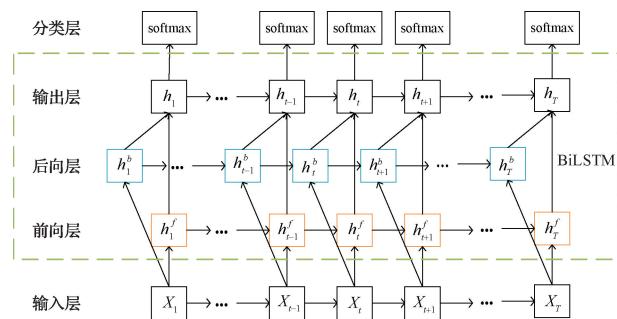


图 3 睡眠阶段转换规则与分期原理

图 3 中, 假设输入序列  $\mathbf{X} = \{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_t, \dots, \mathbf{X}_T\}$ , 其中  $\mathbf{X}_t$  表示  $t$  时刻的特征序列,  $h_t^f$  和  $h_t^b$  分别为  $t$  时刻前向 LSTM 和后向 LSTM 的输出,  $h_t$  为  $t$  时刻 BiLSTM 的输出, 分类算法使用 Softmax 函数进行分类, 最终预测结果的计算公式如下<sup>[21]</sup>:

$$\begin{cases} h_t = \alpha h_t^f + \beta h_t^b \\ y_t = \text{Softmax}(h_t) \end{cases} \quad (15)$$

式中:  $\alpha$  和  $\beta$  为控制前向和后向 LSTM 的加权因子( $\alpha + \beta = 1$ )<sup>[21]</sup>;  $y_t$  为  $t$  时刻的预测结果。

### 1.5 类别加权损失函数

通常睡眠数据存在类别不均衡的问题, 如果使用交叉熵损失函数, 则可能会导致分类结果偏向多样本类别, 会影响模型的分类精度, 所以本文使用类别加权损失函数解决睡眠数据类别不均衡的问题。类别加权损失函数使用的是加权的交叉熵损失函数, 基本思想是给多数类赋予较小的权重值, 给少数类赋予较大的权重值, 如果少数类分类错误, 则会造成较大的损失, 而优化过程是向损失函数

减小的方向优化,因此,会提高小样本类别的分类精度,从而提高模型的总体准确率<sup>[8]</sup>。类别加权损失函数  $L_w$  的定义如下:

$$L_w = -\frac{1}{N} \sum_{k=1}^K \sum_{i=1}^N W_k y_i^k \log(\hat{y}_i^k) \quad (16)$$

式中:  $y_i^k$  为第  $i$  个样本的真实标签;  $\hat{y}_i^k$  为第  $i$  个样本为类别  $k$  的预测概率;  $N$  为样本总数;  $K$  为类别总数;  $W_k$  为分配给  $k$  类别的权重值。

$$W_k = N / (K \times N_k) \quad (17)$$

式中:  $N$  为样本总数;  $N_k$  为  $k$  类别的样本数。

## 2 实验结果与分析

### 2.1 数据集

本文实验数据来源于 PhysioNet 公开的睡眠 Sleep-EDF Database Expanded 数据集。该数据集包含健康受试者的睡眠盒(sleep cassette, SC)记录子集和患有轻度睡眠障碍受试者的睡眠遥测(sleep telemetry, ST)记录子集<sup>[22]</sup>,并主要包括 Fpz-Cz 通道和 Pz-Oz 通道的脑电信号、单通道的眼电信号,采样频率均为 100 Hz。睡眠专家将信号分为 30 s 每期进行人工标记(W 期、N1 期、N2 期、N3 期、N4 期、REM 期、MOVEMENT、UNKNOWN)。

本文实验数据选取 SC 子集中前 20 名受试者的 Fpz-Cz 通道的脑电信号,除受试者 13 丢失第 2 个晚上的睡眠记录外,其余受试者共有两晚的睡眠记录。睡眠分期标准使用 AASM 睡眠分期准则,将 N3 和 N4 期合并为 N3 期,并去除 MOVEMENT 和 UNKNOWN 不相关的睡眠阶段<sup>[23]</sup>,实验数据样本分布情况如表 1 所示。

表 1 实验数据样本分布情况

W	N1	N2	N3	REM	合计
7 927	2 804	17 799	5 703	7 717	41 950

### 2.2 实验设置

本文在 Python 3.7、Pytorch1.11 环境下搭建模型,操作系统是 Windows11,CPU 型号是 Intel(R)Core(TM)i7-11700CPU@2.50 GHz,GPU 型号为 NVIDIA GeForce RTX 3090。

训练过程采用自适应运动估计(adaptive moment estimation, Adam)优化器,学习率为 0.000 005,epoch 设

为 200,batch size 为 256。实验数据按照不同受试者分为 20 份,采用 20 折交叉验证实验,用其中 19 名受试者的脑电信号进行训练模型,剩余 1 名受试者的脑电信号进行评估,重复 20 次训练评估。

### 2.3 评价指标

本文使用不同的评价指标对分期模型进行评估,计算了各期的精确率(precision, P)、召回率(recall, R)、 $F_1$  以及总体准确率(accuracy, ACC)、宏平均  $F_1$  值(macro-averaging  $F_1$ -score, MF<sub>1</sub>)、Cohen's Kappa 系数  $K_c$  以及绘制受试者工作曲线(receiver operating characteristic curve, ROC),不同评价指标的计算公式如下:

$$P = \frac{TP}{TP + FP} \quad (18)$$

$$R = \frac{TP}{TP + FN} \quad (19)$$

$$F_1 = \frac{2PR}{P + R} \quad (20)$$

$$ACC = \frac{\sum_{i=1}^K TP_i}{N} \quad (21)$$

$$MF_1 = \frac{\sum_{i=1}^K F_{1i}}{K} \quad (22)$$

$$K_c = \frac{P_0 - P_e}{1 - P_e} \quad (23)$$

式中:  $TP$  表示正类预测为正类的样本数;  $TN$  表示负类预测为负类的样本数;  $FN$  表示正类预测为负类的样本数;  $FP$  表示负类预测为正类的样本数;  $TP_i$  表示对于  $i$  类被分类正确的样本数;  $F_{1i}$  表示  $i$  类的  $F_1$  值;  $K$  表示类别数;  $N$  表示样本总数;  $P_0$  与 ACC 相等,代表总体准确率。 $p_e$  的计算公式如下:

$$p_e = \frac{(t_1 \times p_1 + t_2 \times p_2 + \dots + t_n \times p_n)}{N \times N} \quad (24)$$

式中:  $t_i$  表示每一类真实的样本数;  $p_i$  表示每一类预测的样本数。

### 2.4 实验结果

本文实验使用 20 折交叉验证后的混淆矩阵和各期评价指标如表 2 所示,各期和宏平均 ROC 曲线如图 4 所示。

表 2 本文模型的混淆矩阵和各期评价指标

分期	W	N1	N2	N3	REM	P/%	R/%	$F_1$ /%
W	<b>7 071</b>	608	61	28	159	90.57	89.20	89.88
N1	423	<b>1 542</b>	412	37	390	46.08	54.99	50.15
N2	140	839	<b>14 592</b>	1 193	1 035	90.88	81.98	86.20
N3	25	10	580	<b>5 082</b>	6	80.13	89.11	84.38
REM	148	347	411	2	<b>6 809</b>	81.07	88.23	84.50

注:加粗的数字表示本文模型分类正确的样本数

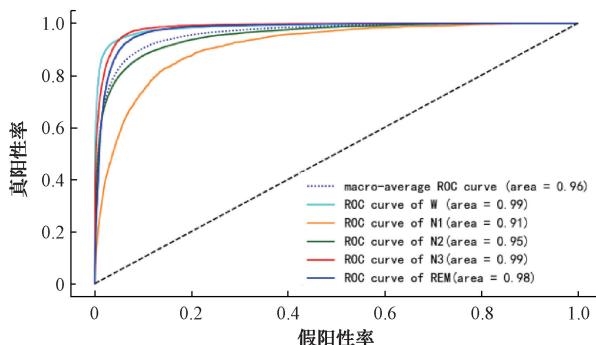


图 4 各期和宏平均 ROC 曲线

从表 2 可以看出, W、N2、N3 和 REM 期的分类结果较好,  $F_1$  值都在 84% 以上, 但 N1 期的分类结果较差, 容易错误地分到 W、N2 和 REM 期。

ROC 曲线结合假阳性率和真阳性率两个指标, 可以更直观地判断分类准确性, AUC 为 ROC 曲线下面积, AUC 值越高, 说明分类性能越好。从图 4 可以看出, W 和 N3 期的 AUC 值最高为 0.99, N1 期的 AUC 值最低为 0.91, 宏平均 AUC 值为 0.96, 说明本文模型在类不平衡的情况下分类性能较好。

本文选取实验数据集中同一名受试者的整晚睡眠记录, 专家给定的分期结果、文献[5, 25-26]模型以及本文模型的分期结果的睡眠时相图如图 5 所示。

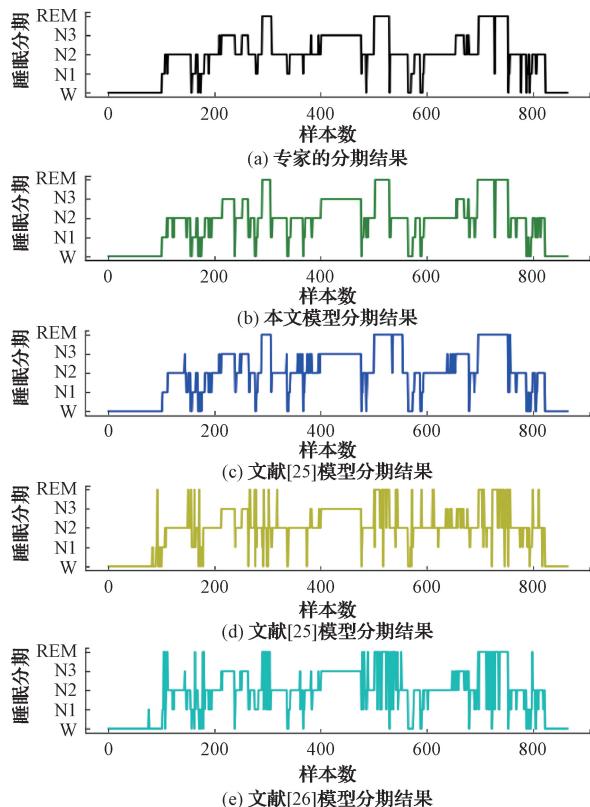


图 5 各模型的分期结果和专家的分期结果

通过图 5 可以观察到, 本文模型在识别不同睡眠阶段的过渡阶段存在部分误判, 可能是因为过渡阶段特征区分度不高, 存在一些误差。但整体上本文模型的分期结果比文献[5, 25-26]的分期结果好, 与专家的分期结果大体一致, 证明了本文模型的有效性。

## 2.5 消融实验对比分析

为了更好地验证本文模型各模块的重要性, 设计了以下消融实验: 实验 1 表示本文方法, 实验 2 表示在实验 1 的基础上去除时频图特征提取模块, 实验 3 表示在实验 1 的基础上去除 ViT 模块, 消融实验的对比结果如图 6 所示。

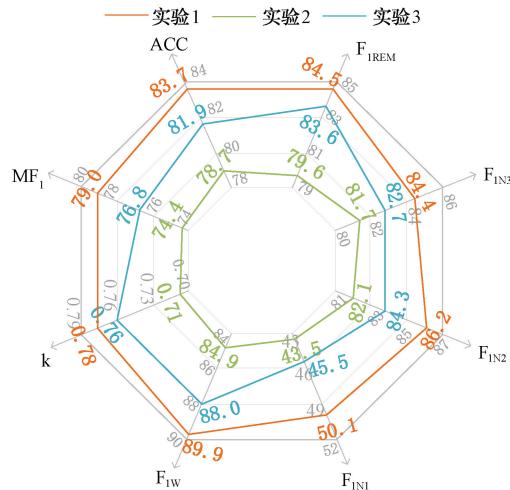


图 6 消融实验的对比结果

由图 6 可以看出, 实验 1 比实验 2、实验 3 的总体准确率、宏平均  $F_1$  值、Cohen's Kappa 系数以及各期的  $F_1$  值都高, 其中, 实验 1 比实验 2、实验 3 的总体准确率分别高 5.0% 和 1.8%。证明了本文采用多视图技术, 从不同视角提取睡眠特征, 以及使用 ViT 模型提取脑电时频图的全局特征的重要性, 有利于提高睡眠分期的准确率。

## 2.6 先前研究成果与本文模型结果对比分析

为了验证本文模型的有效性, 在同一条件下, 与先前的研究成果文献[5, 24-26]进行对比分析, 结果对比如表 3 所示。

文献[5]使用卷积神经网络提取睡眠特征并利用 BiLSTM 学习各睡眠阶段间转换规则。文献[24]使用时频域分析法手动提取特征, 并利用堆叠稀疏自动编码器进行分类。文献[25]使用卷积神经网络自动提取高级特征。文献[26]使用深度残差网络进行端到端分类。

通过表 3 可以看出, 本文模型的总体准确率比文献[5, 24-26]模型的总体准确率分别高 1.7%、4.8%、8.9% 和 3.6%。本文模型和文献[26]模型的  $MF_1$  值相同为 79.0%, 比文献[5, 24-25]模型的  $MF_1$  分别高 2.1%、5.7% 和 9.2%。并且本文模型的 W、N1、N2 和 REM 期的  $F_1$  值也都高于对比模型, 验证了本文模型的有效性, 应用在睡眠分期中有较好的分类效果。

表3 先前研究成果与本文模型结果对比

模型	ACC/%	MF <sub>1</sub> /%	F <sub>1</sub> /%				
			W	N1	N2	N3	REM
文献[5]	82.0	76.9	84.7	46.6	85.9	84.8	83.4
文献[24]	78.9	73.3	71.6	47.0	84.6	84.0	81.4
文献[25]	74.8	69.8	65.4	43.7	80.6	<b>84.9</b>	74.5
文献[26]	80.1	<b>79.0</b>	85.9	38.7	84.4	82.5	76.5
本文	<b>83.7</b>	<b>79.0</b>	<b>89.9</b>	<b>50.1</b>	<b>86.2</b>	84.4	<b>84.5</b>

### 3 结 论

本文提出了一种基于多视图与注意力机制的睡眠脑电分期方法,根据原始脑电信号构造时域和时频域两类视图数据。针对时域视图,采用多尺度 CNN 和残差 SE 块对其提取特征和自适应特征校准。针对时频域视图,构建 CNN 和 ViT 并行网络,联合学习脑电时频图的局部-全局信息。再融合两类视图提取的特征,输入到 BiLSTM 中挖掘各睡眠阶段间的转换规则。此外,本文使用类别加权损失函数解决睡眠数据类别不均衡的问题。本文实验使用 Sleep-EDF 中 20 名受试者的 Fpz-Cz 通道的脑电数据进行留一受试者交叉验证,准确率最高达到 92.9%,准确率最低为 74.9%,平均准确率达到 83.7%,不同受试者的准确率标准差为 4.9%,说明不同受试者间的准确率波动小,证明了本文模型适应于不同受试者的脑电数据,具有良好的泛化性能和鲁棒性,并且本文模型的整体准确率和 N1 期的 F<sub>1</sub> 值都优于现有模型,说明本文模型提高了小样本的分类精度,应用在睡眠分期中有较好的分期效果。

### 参 考 文 献

- [1] LUYSTER F S, STROLLO JR P J, ZEE P C, et al. Sleep: A health imperative[J]. Sleep, 2012, 35(6): 727-734.
- [2] 张媛媛,李丕丁,孔祥勇.基于 STM32 睡眠呼吸机的系统设计[J].电子测量技术,2021,44(9):42-47.
- [3] 戴凤智,芦鹏,朱宇璇.基于多传感器的睡眠监测与评估系统设计[J].国外电子测量技术,2022,41(4): 126-133.
- [4] 杨飞帆,陈振东,刘惠鹏.依托眼罩的睡眠监测方法[J].电子测量技术,2019,42(22):155-159.
- [5] 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.
- [6] KOLEY B, DEY D. An ensemble system for automatic sleep stage classification using single channel EEG signal[J]. Computers in Biology and Medicine, 2012, 42(12): 1186-1195.
- [7] ZHAO D, WANG Y, WANG Q, et al. Comparative analysis of different characteristics of automatic sleep stages [J]. Computer Methods and Programs in Biomedicine, 2019, 175: 53-72.
- [8] 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.
- [9] 王涛,鲁昌华,孙怡宁,等.多尺度卷积神经网络检测睡眠呼吸暂停[J].电子测量与仪器学报,2021, 35(7):30-35.
- [10] 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.
- [11] KHALIL E, ASL B M. Automatic sleep stage classification using temporal convolutional neural network and new data augmentation technique from raw single-channel EEG[J]. Computer Methods and Programs in Biomedicine, 2021, 204: 106063.
- [12] 金峰,贾克斌,袁野.基于混合注意力时序网络的睡眠分期算法研究[J].生物医学工程学杂志,2021, 38(2):241-248.
- [13] 郭钰荣,姚金杰,白建胜,等.基于 FEEMD 算法对小样本电磁信号的识别与分类[J].国外电子测量技术, 2023,42(4):166-172.
- [14] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [15] CAI X, JIA Z, TANG M, et al. Brainsleepnet: Learning multivariate EEG representation for automatic sleep staging[C]. 2020 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). IEEE, 2020: 976-979.
- [16] 张书恒,李军,张礼轩,等.一种融合间接注意力的自适应特征提取方法[J].电子测量技术,2022,45(21): 75-81.
- [17] 韩亮,罗统军,蒲秀娟,等.使用多尺度递归图和视觉转换器的心律失常分类[J].仪器仪表学报,2022, 43(12):149-157.
- [18] 杨彦辰,云利军,梅建华,等.基于改进 ViT 的红外

- 人体图像步态识别方法研究[J]. 应用光学, 2023, 44(1):71-78.
- [19] 王雷, 何坤, 李宗帅, 等. 基于 BiLSTM-Attention 的迁移学习变工况故障识别方法研究[J]. 电子测量与仪器学报, 2023, 37(7):205-212.
- [20] 刘辉, 李永康, 高放, 等. 基于小波散射协同 BiLSTM 的输电线路故障诊断[J]. 国外电子测量技术, 2021, 40(12):165-172.
- [21] 罗森林, 郝靖伟, 潘丽敏. 基于 CNN-BiLSTM 的自动睡眠分期方法[J]. 北京理工大学学报, 2020, 40(7): 746-752.
- [22] SEO H, BACK S, LEE S, et al. Intra-and inter-epoch temporal context network (IITNet) using sub-epoch features for automatic sleep scoring on raw single-channel EEG[J]. Biomedical Signal Processing and Control, 2020, 61: 102037.
- [23] BERRY R B, BROOKS R, GAMALDO C E, et al. The AASM manual for the scoring of sleep and associated events [J]. Rules, Terminology and Technical Specifications, Darien, Illinois, American Academy of Sleep Medicine, 2012, 176: 2012.
- [24] TSINALIS O, MATTHEWS P M, GUO Y. Automatic sleep stage scoring using time-frequency analysis and stacked sparse autoencoders[J]. Annals of Biomedical Engineering, 2016, 44: 1587-1597.
- [25] TSINALIS O, MATTHEWS P M, GUO Y, et al. Automatic sleep stage scoring with single-channel EEG using convolutional neural networks [J]. Statistics, 2016, DOI:10.48550/arXiv.1610.01683.
- [26] HUMAYUN A I, SUSHMIT A S, HASAN T, et al. End-to-end sleep staging with raw single channel EEG using deep residual convnets [C]. 2019 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI). IEEE, 2019: 1-5.

#### 作者简介

李兰亭,硕士研究生,主要研究方向为脑机接口。

E-mail:1249572022@qq.com

苗敏敏(通信作者),博士,副教授,主要研究方向为生物信号处理、脑机接口。

E-mail:02746@zjhu.edu.cn