

# 采用小波变换和双向长短期记忆网络的 脑电睡眠分期模型

王天宇<sup>1</sup>, 陈晗<sup>1</sup>, 王刚<sup>2,3</sup>, 吴宁<sup>1</sup>

(1. 西安交通大学电子与信息学部, 710049, 西安; 2. 西安交通大学生物医学信息工程教育部  
重点实验室, 710049, 西安; 3. 西安交通大学生命科学与技术学院, 710049, 西安)

**摘要:** 针对睡眠生理信号采集难度大、睡眠分期精度低的问题,提出一种采用小波变换和双向长短期记忆网络的脑电睡眠分期模型。首先使用连续小波变换提取睡眠脑电的时频图;然后使用卷积神经网络从脑电信号的时频图中提取睡眠相关的脑电特征,作为单个睡眠片段的分期依据,再使用双向长短期记忆网络进一步提取睡眠片段之间的状态转换规则;最后利用深度学习方法建立特征、规则与睡眠阶段的映射,使用数据扩充和两步训练法训练模型,削弱数据不均衡的影响,完成连续片段的睡眠分期。采用 SHHS 公开数据库的 5 793 名被试者的睡眠脑电数据对该模型进行验证,实验结果表明,睡眠分期准确率达到 85.82%,整体 F1 达到 78.39,Kappa 系数达到 0.799,和现有方法相比性能明显提升。

**关键词:** 睡眠分期;脑电信号;连续小波变换;卷积神经网络;双向长短期记忆网络

**中图分类号:** TN911.6   **文献标志码:** A

**DOI:** 10.7652/xjtuxb202209011   **文章编号:** 0253-987X(2022)09-0104-08



OSID 码

## EEG Sleep Staging Model Using Wavelet Transform and Bidirectional Long Short-Term Memory Network

WANG Tianyu<sup>1</sup>, CHEN Han<sup>1</sup>, WANG Gang<sup>2,3</sup>, WU Ning<sup>1</sup>

(1. Faculty of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China; 2. The Key Laboratory of Biomedical Information Engineering of Ministry of Education, Xi'an Jiaotong University, Xi'an 710049, China; 3. School of Life Science and Technology, Xi'an Jiaotong University, Xi'an 710049, China)

**Abstract:** For the difficulty in acquisition of physiological signals and low accuracy of sleep staging, an EEG sleep staging model using wavelet transform and bidirectional long short-term memory network is proposed. First, the time-frequency map of raw sleep EEG is extracted by using continuous wavelet transform. Then, the sleep-related EEG features are extracted from the time-frequency map through the VGG convolutional network as the staging basis for a single sleep segment, and the transition rules of sleep state are further extracted by the bidirectional long short-term memory network. Finally, the deep learning method is used to establish the mapping of features, rules and sleep stages, and the data augmentation and two-step training methods are used to train the model to weaken the influence of data imbalance and complete the continuous sleep staging work. The model is verified by the sleep EEG data of 5 793 subjects from the public database SHHS. The experimental results show that the sleep staging accuracy of the model reaches 85.82%, the F1 reaches 78.39, and the Kappa index reaches 0.799. Compared with

existing methods, the performance of the proposed model is significantly improved.

**Keywords:** sleep stages; electroencephalogram signals; continuous wavelet transform; convolutional neural networks; bidirectional long short-term memory networks

睡眠是人类最重要的生理活动之一,拥有正常睡眠对维持大脑稳定和人的身心健康十分重要。世界卫生组织调查显示,27%的人有睡眠问题。研究表明,睡眠异常是心血管病、肥胖症、抑郁症和焦虑症等多种疾病的诱因<sup>[1]</sup>。因此,睡眠障碍已经成为威胁世界公众的突出问题。

睡眠分期是睡眠异常诊断的重要手段。在临床上,专业睡眠医师通过采集病人的多导睡眠图(PSG),并依照美国睡眠医学学会 AASM 睡眠分期标准<sup>[2]</sup>进行人工睡眠分期,分为快速眼动期(REM)、非快速眼动1期(N1)、非快速眼动2期(N2)、非快速眼动3期(N3)、清醒期(W),但是人工睡眠分期效率较低、成本高昂<sup>[3]</sup>。有许多基于多导信号进行自动睡眠分期的研究。Kuo 等从脑电、心电、眼电信号中提取多种特征,使用堆叠的长短期记忆网络(LSTM)构建了睡眠分期模型<sup>[4]</sup>,实验中的最佳准确率达到83.7%;Patanaiik 等使用短时傅里叶变换从多通道脑电和眼电信号中提取时频图,并使用深度卷积神经网络(CNN)和多层感知机构建模型<sup>[5]</sup>,能够进行实时睡眠分期;Phan 等同样使用短时傅里叶变换从多通道生理信号中提取时频图,并使用滤波器组和带注意力机制的双向循环神经网络(RNN)构建了 SeqSleepNet 模型<sup>[6]</sup>,在小数据集上准确率达到87.1%;Perslev 等<sup>[7]</sup>和 Jia 等<sup>[8]</sup>分别使用 U 型结构的深度神经网络模型来捕获脑电和眼电信号中的显著特征和睡眠状态转换规则,能够有效进行睡眠分期。基于多导生理信号的睡眠分期模型,虽然能够得到较高的准确率,但是由于采集的信号较多,计算复杂度较大,故采用单通道生理信号进行睡眠分期,保证相同水平的准确率,同时降低生理信号采集难度、减小计算复杂度,是一个值得探索的方向<sup>[9]</sup>。脑电信号(EEG)能够直接反映人脑状态,在基于单通道信号的睡眠分期研究中有着天然的优势。

Supratak 等基于单通道 EEG 使用不同大小的一维卷积神经网络和双向长短期记忆网络(BiLSTM),设计了睡眠分期模型 DeepSleepNet<sup>[10]</sup>,并在随后的研究中对模型进行简化,构建了用小卷积核的一维 CNN 和长短期记忆网络组合的 TinySleepNet 模型<sup>[11]</sup>。两个模型都以单通道 EEG 作为

输入,用 39 人和 197 人的小数据集进行了实验验证,准确率分别达到 82%和 85.4%;Korkalainen 等使用三层堆叠的卷积池化块和 BiLSTM<sup>[12]</sup>,基于脑电信号进行睡眠分期,在 39 人的数据集上准确率达到 83.7%,并与脑电结合眼电的方法在多个数据集上进行了比较,结果显示准确率差异在 1%以内;Qu 等自然语言处理领域获得灵感,同样以单通道 EEG 作为输入,采用自编码器构建了睡眠分期网络<sup>[13]</sup>,在 200 人和 197 人的数据集上进行实验,准确率达到 84.3%;Zhou 等通过公式计算从单通道 EEG 中提取 108 维特征,并利用随机森林和 LGB 构建了双层堆叠分类器<sup>[14]</sup>,在 8 人和 197 人的小数据集上达到了较高的准确率;Jiang 等利用频域和时域分解从单通道 EEG 中提取特征,并利用随机森林和隐马尔可夫模型构建分类器<sup>[15]</sup>,在 8 人、20 人和 61 人的小数据集上准确率达到 89.4%。相对于从 EEG 原始信号中利用 CNN 提取的抽象特征,利用信号分析方法能够更直观有效地提取出 EEG 的时频域特征。现有研究多基于小数据集进行建模,数据采集周期短,数据稳定性较高,而实际大规模应用中,不同批次的睡眠数据往往存在一定的差异性,所以模型的准确率和稳定性较差。

本文提出了一种采用小波变换和 BiLSTM 的脑电睡眠分期模型,预先计算单通道 EEG 的时频图,再利用二维卷积网络提取时频特征,进一步使用双向长短期记忆网络来捕捉睡眠状态转换规则,并使用大数据集验证,得到了性能优秀的睡眠分期模型。

## 1 睡眠分期模型

采用小波变换和 BiLSTM 的睡眠分期模型主要包含 3 个部分:睡眠脑电时频图的提取与压缩;二维卷积网络时频特征的提取;睡眠状态转换规则的提取与睡眠分期。采用小波变换和 BiLSTM 的睡眠分期模型结构如图 1 所示。

### 1.1 睡眠脑电时频图的提取与压缩

连续小波变换(CWT)是一种多尺度时频分析方法,可以由粗到细地逐步分析信号,是进行脑电信号时频分析和处理的理想工具<sup>[16-17]</sup>。

小波变换的公式如下




图1 采用小波变换和 BiLSTM 的睡眠分期模型结构

Fig. 1 Sleep stage model structure based on CWT and BiLSTM

$$\text{CWT}(a; \tau) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \psi\left(\frac{t-\tau}{a}\right) dt \quad (1)$$

式中:  $f(t)$  为输入的脑电信号;  $a$  为尺度;  $\tau$  为偏移量。

将脑电信号按照 30 s 时长划分为多个连续片段组成的序列,如下式

$$x_{\text{seg}}^{(i)} = x[i:i+30f_s], i \in [0, 1, \dots, n_{\text{seg}}] \quad (2)$$

利用小波变换从原始脑电信号起始处开始,依次计算每一个 30 s 片段的小波时频图,直到信号末尾,如下式

$$x_{\text{cwt}}^{(i)} = \text{CWT}(x_{\text{seg}}^{(i)}) \quad (3)$$

连续片段的小波时频图重新组成序列,如下式

$$X_{\text{cwt}} = [x_{\text{cwt}}^{(0)}, x_{\text{cwt}}^{(1)}, \dots, x_{\text{cwt}}^{(n_{\text{seg}})}] \quad (4)$$

式中:  $f_s$  为采样频率;  $x$  为原始信号;  $x_{\text{seg}}^{(i)}$  是经过分割后的第  $i$  个片段;  $n_{\text{seg}} = \lfloor L_{\text{raw}}/30f_s \rfloor$  为从原始信号中分割的 30 s 片段的个数,  $L_{\text{raw}}$  为原始信号长度,  $\lfloor \cdot \rfloor$  表示向下取整;  $x_{\text{cwt}}^{(i)}$  为第  $i$  个片段经过小波变换后得到的小波时频图;  $X_{\text{cwt}}$  为多个连续片段得到的小波时频图组成的序列。

由于时频图在时间维度上过大,为降低数据维度,提高神经网络训练速度,将小波时频图通过加窗求均值的方式进行时间采样点数的压缩。将每  $m$  个点的值相加求得均值,作为压缩后的值,如下式

$$x_{\text{zcwt}}(t) = \sum_{\tau=t}^{t+m} x_{\text{cwt}}(\tau)/m, t \in [0, 1, \dots, l_z] \quad (5)$$

式中:  $m$  表示连续压缩点数;  $l_z = \lfloor 30f_s/m \rfloor$  表示压缩后的时间采样点数;  $x_{\text{zcwt}}$  为经过压缩后的小波时频图。

## 1.2 二维卷积特征提取

不同睡眠状态下的 EEG 中各频带幅度随时间的改变不同<sup>[18]</sup>, EEG 频率的强弱是大脑活动强度的最直接体现,小波时频图能够在各频带上体现不同尺度的时频域信息。通过二维卷积网络,可以进一步提取出小波时频图中的时频域特征。依据视觉几何组 (visual geometry group, VGG) 提出的 VGGNet<sup>[19]</sup> 构建了一个二维卷积神经网络,如图 2 所示。




图2 基于 VGG 的二维卷积神经网络

Fig. 2 2-d CNN based on VGG

二维卷积神经网络主要包含 4 个卷积池化块,每个卷积核大小均为 (3, 3),卷积核的个数依次为 32、48、64、72,每个卷积池化块包含 2 次卷积运算,1 次池化运算,每层依次计算得到特征向量如下式

$$\mathbf{X}_{f1} = \text{CPBlock1}(\mathbf{X}_{\text{zcwt}}) \quad (6)$$

$$\mathbf{X}_{f2} = \text{CPBlock2}(\mathbf{X}_{f1}) \quad (7)$$

$$\mathbf{X}_{f3} = \text{CPBlock3}(\mathbf{X}_{f2}) \quad (8)$$

$$\mathbf{X}_{f4} = \text{CPBlock4}(\mathbf{X}_{f3}) \quad (9)$$

经过 4 个堆叠卷积和池化计算后得到特征向量  $\mathbf{X}_{f4}$ ,再进行 1 次卷积池化运算进一步缩减特征维数,得到特征向量  $\mathbf{X}_{f5}$  如下式

$$\mathbf{X}_{f5} = \text{CPBlock5}(\mathbf{X}_{f4}) \quad (10)$$

将特征展平得到时频特征向量  $\mathbf{X}_{\text{VGG}}$ ,如下式

$$\mathbf{X}_{\text{VGG}} = \text{Reshape}(\mathbf{X}_{f5}) \quad (11)$$

式中:  $\mathbf{X}_{f1}$ 、 $\mathbf{X}_{f2}$ 、 $\mathbf{X}_{f3}$ 、 $\mathbf{X}_{f4}$ 、 $\mathbf{X}_{f5}$  表示 5 个卷积池化块的输出; CPBlock1、CPBlock2、CPBlock3、CPBlock4、

CPBlock5 表示网络中的卷积池化运算;Reshape 表示将时频特征展平为特征向量; $\mathbf{X}_{\text{VGG}}$  表示二维卷积网络提取出的时频特征向量。

1.3 睡眠状态转换规则提取与睡眠分期

睡眠状态转换规则具有明显的时间相关性和阶段性<sup>[20]</sup>。在睡眠分期规则中,当前片段的睡眠分期既要考虑前向的变化也要考虑后向的变化。长短期记忆网络通过沿着时间传递隐状态和细胞状态,能够学习到时序数据中的抽象特征<sup>[21]</sup>。BiLSTM<sup>[22]</sup>通过让两个 LSTM 分别独立的处理前向和后向输入序列,并将两个方向得到的特征向量组合,同时利用来自过去和未来的信息。本文使用了 BiLSTM 从特征图中进一步计算睡眠状态转换规则,并得到最终的睡眠分期结果。

模型采用的 BiLSTM 细胞核数为 128,丢弃概率为 0.5,采用双向结构,通过 BiLSTM 得到前向和后向的隐向量,如下式

$$\mathbf{h}_f^{(t)} = \text{LSTM}(\mathbf{h}_f^{(t+1)}, \mathbf{x}_{\text{VGG}}^{(t)}) \tag{12}$$

$$\mathbf{h}_b^{(t)} = \text{LSTM}(\mathbf{h}_b^{(t-1)}, \mathbf{x}_{\text{VGG}}^{(t)}) \tag{13}$$

式中: $\mathbf{x}_{\text{VGG}}^{(t)}$ 表示  $t$  时刻二维卷积网络提取的时频特征向量; $\mathbf{h}_f^{(t)}$ 、 $\mathbf{h}_b^{(t)}$  分别表示前向和后向 LSTM 的隐向量。

$\mathbf{h}_f^{(t)}$ 、 $\mathbf{h}_b^{(t)}$  拼接在一起构成 BiLSTM 的隐向量,蕴含了睡眠状态转换规则。进一步利用 Softmax 激活得到睡眠分期结果

$$\mathbf{y}^{(t)} = \text{Softmax}(\mathbf{h}_f^{(t)}, \mathbf{h}_b^{(t)}) \tag{14}$$

2 数据集和实验结果

2.1 数据集

睡眠心脏健康研究(SHHS)<sup>[23-24]</sup>由美国心肺血液研究所开展,从多个中心收集数据,旨在确定睡眠呼吸障碍和心血管疾病的关联。数据子集 1 包含 5 793 名被试者的 PSG 记录,其中 EEG 采集两通道数据(C4-A1、C3-A2),采样频率为 125 Hz。睡眠专家根据 R&K 标准标注睡眠阶段。

实验选用了 C3-A2 通道的 EEG,降采样到 100 Hz,并且将每条记录按照 30 s 一个片段进行分段。本文采用了两种样本分割方式:以单个 30 s 片段作为样本进行预训练;以连续多个 30 s 片段组成的序列作为样本进行微调。

由于每个记录的开始和结束部分包含长时间清醒阶段,本文对数据进行了清洗,表 1 为数据分割清洗后每类睡眠阶段数的统计,其中  $R$  表示每类睡眠阶段数占所有睡眠阶段数的比例。以第一个睡眠期

出现之前 30 min 为新起始点,以最后一个睡眠期结束 30 min 后为新终止点,丢弃原起始点和新起始点之间的清醒阶段以及新终止点和原终止点之间的清醒阶段。AASM 标准相比 R&K 标准应用更广泛,故去除了标记为运动和未知的阶段,将睡眠标注转化为 AASM 标准中的 W、N1、N2、N3、REM 5 类。

表 1 SHHS 数据集每类睡眠阶段数统计  
Table 1 Statistics on sleep stages of SHHS-1

| 睡眠阶段类别 | 睡眠阶段数     | $R/\%$ |
|--------|-----------|--------|
| W      | 1 169 272 | 21.89  |
| N1     | 217 553   | 4.07   |
| N2     | 2 396 996 | 44.88  |
| N3     | 739 356   | 13.84  |
| REM    | 817 278   | 15.30  |
| 总计     | 5 340 455 |        |

2.2 睡眠分期模型训练过程

2.2.1 数据扩充

由表 1 可得,虽然数据清洗去除了部分清醒期,但是整个数据集仍然处于极其不均衡的状态,N1 睡眠阶段数远远小于其他睡眠阶段数。为了增强模型对小类别的判别能力,进一步使用数据扩充方法处理数据集,并在训练 VGG 时使用数据扩充后的数据。数据扩充过程如下:首先统计每个睡眠记录中所有睡眠阶段数,以最多数作为数据扩充上限。然后对于数量不足的睡眠阶段,随机选取样本进行复制,直到此类睡眠阶段数达到数据扩充上限。通过复制扩充了小类别的样本数,使数据集整体达到均衡状态。

2.2.2 训练算法

为了强化模型对于不平衡数据集的学习和判别能力,通过数据扩充进行了数据增强,提高了模型的性能和鲁棒性<sup>[25]</sup>,但是这破坏了原有的时序连续性<sup>[26]</sup>,无法使用 BiLSTM 直接进行学习。因此采用了两步训练的方法,即第一步先使用扩充后的均衡数据集训练 VGG,第二步微调过程中再将 VGG 隐藏层连接到 BiLSTM,使用原始数据集进行微调学习。

具体来说,第一阶段训练时,在 VGG 的最后一层隐藏层后拼接一个全连接层,以 Softmax 作为激活函数,单个 30 s 片段作为输入,对应的标签作为输出,使用 Adam 优化器,学习率设置为  $10^{-5}$ ,并用早停法决定停止学习的 epoch。在训练结束后,丢弃 Softmax 层及相应的参数,将特征图展平。

在第二阶段微调时,将训练好的 VGG 参数导入到完整的网络模型中,以连续 50 个片段组成的序列作为输入,对应的标签序列作为输出,使用 Adam 优化器,对于训练好的 VGG 设置较小的学习率  $10^{-7}$ ,对于还未训练的 BiLSTM 设置原本的学习率  $10^{-5}$ ,以避免网络过拟合,并用早停法决定停止学习的 epoch。

2.2.3 实验实施

由于 SHHS 数据集有 5 793 条记录,本文以 8:1:1 的比例随机划分了训练集、验证集、测试集,即随机挑选了 4 635 条记录作为训练集,579 条记录作为验证集,剩余的 579 条记录作为测试集。使用早停法在训练集和验证集上将模型最优化,最后在测试集上得到最终的性能评价。

基于 Python 编程语言(版本号 3.7),使用 Pytorch1.8 深度学习框架实现了本文的模型,实验平台配置为:CPU 型号为 Intel(R) Xeon(R) Gold 6240 CPU @ 2.60 GHz,内存容量为 256 GB,GPU 型号为 NVIDIA GeForce RTX 3090。模型实际训练花费时间约为 10 h。

2.2.4 评价方法

使用准确率(A)、每类精度(P)、每类召回率(R)、每类 F1 分数( $F_1$ )、宏平均 F1 分数( $F_{1M}$ )和 Cohen's Kappa 系数( $\kappa$ )来评估模型的性能。F1 分数能够较为精准地评估模型不平衡数据分类的性能,宏平均 F1 分数为各类 F1 分数的均值。Cohen's Kappa 系数能够综合反映模型分期结果和睡眠专家分期结果之间的一致性。A、P、R、 $F_1$ 、 $F_{1M}$  和  $\kappa$  的表达式如下

$$A = \frac{T_P + T_N}{T_P + F_P + T_N + F_N} \tag{15}$$

$$P = \frac{T_P}{T_P + F_P} \tag{16}$$

$$R = \frac{T_P}{T_P + F_N} \tag{17}$$

$$F_1 = \frac{2PR}{P + R} \tag{18}$$

$$F_{1M} = \frac{1}{n} \sum_{i=1}^n F_{1i} \tag{19}$$

$$\kappa = \frac{p_o - p_e}{1 - p_e} \tag{20}$$

$$p_e = \frac{t_1 p_1 + t_2 p_2 + \cdots + t_n p_n}{N^2} \tag{21}$$

式中: $T_P$ 、 $F_P$ 、 $T_N$ 、 $F_N$  是实验分类结果中各类别的数量, $T_P$  为真阳性,表示分类正确的正例; $F_P$  为假阳性,表示分类错误的正例; $T_N$  为真阴性,表示分类正确的反例; $F_N$  为假阴性,表示分类错误的反例; $p_o$  与 A 相等,表示总体的准确率; $t_i$  表示每一类真实的样本个数; $p_i$  表示模型预测出来的每一类预测的样本个数; $N$  为样本总数。

2.3 实验结果对比与分析

模型在 SHHS 数据集上进行了实验,表 2 给出了 3 个不同的基线模型和本文提出的模型的对比结果。3 个基线模型包括 DeepSleepNet(DSN)、TinySleepNet(TSN) 和 SeqSleepNet(SSN)。DeepSleepNet 使用不同大小的一维 CNN 提取抽象特征,并利用 BiLSTM 学习睡眠阶段之间的转换规则;TinySleepNet 使用简单的 CNN 和单向 LSTM 构建的睡眠分期模型;SeqSleepNet 由滤波器组和用于编码睡眠序列信息的双向 RNN 组成。原文使用了 EEG、EOG、EMG 三通道数据,为形成有效对比,复现时仅使用了 EEG 通道。

对比的参数包括准确率 A、 $F_{1M}$ 、 $\kappa$  和  $F_1$ 。由于基线模型没有在 SHHS 上进行过实验,根据论文中的描述,重新实现了基线模型并在 SHHS 上进行了实验。与其他模型相比,本文的模型整体表现最好,在整体的评价指标上均达到了最高,并且由于采用了数据扩充算法,增强了模型对 N1 阶段等小样本类别的学习能力,所以本文的模型对于 N1 阶段的识别能力也较为优秀。

表 2 本文提出的模型实验结果与基线模型结果  
Table 2 The results of proposed model and the baseline model

| 模型   | A/%   | $F_{1M}$ | $\kappa$ | $F_1$ |       |       |       |       |
|------|-------|----------|----------|-------|-------|-------|-------|-------|
|      |       |          |          | W     | N1    | N2    | N3    | REM   |
| DSN  | 82.98 | 77.25    | 0.761    | 87.77 | 51.18 | 85.2  | 80.65 | 81.47 |
| TSN  | 81.78 | 74.12    | 0.748    | 88.53 | 38.50 | 83.57 | 82.02 | 77.99 |
| SSN  | 84.31 | 76.39    | 0.776    | 89.85 | 42.09 | 87.23 | 79.3  | 83.46 |
| 本文模型 | 85.82 | 78.39    | 0.799    | 90.59 | 45.51 | 87.66 | 79.34 | 88.84 |

使用原始脑电信号作为输入的网络,例如 DeepSleepNet 和 TinySleepNet 等能够在一定程度上划分不同的睡眠周期,但是采用原始信号作为输入无法完全捕捉到不同睡眠阶段的时频特征;SeqSleepNet 模型使用了短时傅里叶变换和滤波器组捕捉脑电信号中的时频特征,所以其性能相对较好,但是本文的模型利用连续小波变换更有效地捕捉了时频特征,因此比其他模型有更好的表现。

多数基线模型在 SHHS 数据集上未能完全表现出原本的性能,这是由于生理信号数据的稳定性易受采集时间、地点、设备等客观因素影响,基线模型使用的小数据集 PSG 记录数为 39 或 153,采集周期较短、采集地点固定,数据较为稳定,所以基线模型表现较好。SHHS 数据集记录数多达 5 793,采集周期长,受客观因素影响数据稳定性较低,所以基线模型在 SHHS 数据集上性能有所降低。

3 方法优化的考虑

3.1 小波时频图时间采样点数对模型性能的影响

为确定连续小波变换得到的时频图时间采样点数大小对于模型性能的影响,进行了不同时间采样点数的比较实验。原时频图采样时间为 30 s,采样频率为 100 Hz,由采样时间乘采样频率可得时间采样点数为 3 000(100 Hz×30 s)。将原本时间采样点数为 3 000 的数据通过加窗求平均值的方式,压缩为原本的 1/200、1/100、1/50、1/30、1/25、1/20、1/15、1/12,得到新的时频图时间采样点数分别为 15、30、60、100、120、150、200 和 250,实验结果如图 3 所示。




图 3 不同时间采样点数的实验结果

Fig. 3 Results of different time sampling size

从实验结果可得,当时间采样点数小于 200 时,模型性能较低,当时间采样点数等于 200 时,模型性能达到最高,且在超过 200 时模型性能不再明显提升,因此最终确定时间采样点数为 200。

3.2 LSTM 与 BiLSTM 性能比较

为了确定 LSTM 双向结构相对于单向结构的性能提升,设计并进行了 LSTM 与 BiLSTM 的实验结果比较,如图 4 所示。LSTM 为 128 个记忆单元的单层单向结构;BiLSTM 为 128 个记忆单元的单层双向结构。




图 4 LSTM 与 BiLSTM 的实验结果比较

Fig. 4 Comparison of results between LSTM and BiLSTM

图 4 中  $F_{1N1}$  表示 N1 阶段的 F1 分数,  $F_{1N2}$  表示 N2 阶段的 F1 分数,  $A$ 、 $F_{1M}$ 、 $\kappa$  为整体性能指标。BiLSTM 的各项评价指标均优于 LSTM。这是由于在睡眠分期中,相比于单向结构的网络,双向结构的网络和睡眠状态转换规则更加契合。睡眠状态转换规则不是一个在时间上单向确定的规则,在人工睡眠分期的过程中,睡眠专家通过睡眠状态转换规则和相邻的已确定的睡眠阶段来确定当前睡眠阶段,这不只包括之前的睡眠阶段,也包括之后的睡眠阶段。只有采用双向结构,同时考虑前向和后向,才能更完整的捕捉睡眠状态转换规则。

3.3 数据扩充和两步训练算法的作用

在第一阶段训练二维卷积神经网络时,采用了数据扩充算法来强化模型对于小样本类别的学习能力,并且进一步使用微调的方法调整模型。为了证明数据扩充和两步训练算法的有效性,设计并进行了实验,结果见表 3。不扩充指不使用数据扩充和两步训练算法,模型直接以连续序列数据作为输入进行一步训练;复制扩充指本文所使用的数据扩充算法,使用复制的方式进行数据扩充,并使用两步训练算法完成模型训练;平移扩充指使用平移数据的方式扩充数据,即将小样本片段随机左右平移 0~3 s 的数据扩充算法,保持样本标签不变,并使用两步训练算法完成模型训练。

从表 3 结果可得,数据扩充和两步训练算法对

于模型性能提升有显著效果,模型在第一阶段,通过数据扩充算法,强化了对于小样本类别的识别能力,这使得模型的性能大大提升;同时,不同的数据扩充算法对于模型性能的影响不显著,为了减少计算复杂度,本文没有采用更复杂的平移扩充算法,而是使用了简单且有效的复制扩充算法。

表 3 数据扩充及两步训练算法实验结果比较  
Table 3 Comparison between various training algorithms

| 扩充算法 | $A/\%$ | $F_{1M}$ | $\kappa$ | $F_{1N1}$ | $F_{1N2}$ |
|------|--------|----------|----------|-----------|-----------|
| 不扩充  | 81.62  | 72.67    | 0.738    | 34.38     | 83.78     |
| 复制扩充 | 85.82  | 78.39    | 0.799    | 45.51     | 87.66     |
| 平移扩充 | 85.60  | 78.35    | 0.796    | 45.49     | 87.23     |

#### 4 结论和展望

本文采用小波变换和 BiLSTM 构建了一种单通道脑电睡眠分期模型,利用连续小波变换针对不同睡眠状态 EEG 中各频带分布不同的特性,计算睡眠脑电的时频图;利用基于 VGGNet 的二维卷积网络提取其中的时频域信息,进一步使用 BiLSTM,有效提取睡眠状态转换规则并进行睡眠分期。针对数据集中睡眠阶段数不均衡的特点,采用了数据扩充和两步训练算法训练模型,并在大数据集上进行了测试。睡眠分期 5 分类的准确率  $A$  达到 85.82%,  $F_{1M}$  达到 78.39,  $\kappa$  达到 0.799。本文构建的模型精度更高、稳定性更好,证实了小波变换提取睡眠 EEG 时频域信息相比于一维卷积网络直接计算更有效。

本文的方法仍有一些不足之处:数据扩充和两步训练算法虽然能够提升睡眠分期 N1 阶段的精度,但是无法彻底消除样本数不均衡的影响,未来仍需要不断探究更好的均衡策略;时频图需要经过压缩才能够利用二维卷积网络进一步提取特征,而时间采样点数的减小定然会造成时域信息的损失,进而影响模型的精度,未来仍需改进模型结构,弥补时域信息的损失。

#### 参考文献:

[1] 赵忠新. 睡眠医学 [M]. 北京: 人民卫生出版社, 2016.

[2] MOSER D, ANDERER P, GRUBER G, et al. Sleep classification according to AASM and Rechtschaffen & Kales: effects on sleep scoring parameters [J]. Sleep, 2009, 32(2): 139-149.

[3] 徐富献, 王抒伟, 钱钊钰, 等. 睡眠自动分期方法综述 [J]. 生物物理学, 2019, 7(3): 34-48.

XU Fuxian, WANG Shuwei, QIAN Xiangyu, et al. A review of automatic sleep staging [J]. Biophysics, 2019, 7(3): 34-48.

[4] KUO C E, CHEN Guanting. Automatic sleep staging based on a hybrid stacked LSTM neural network: verification using large-scale dataset [J]. IEEE Access, 2020, 8: 111837-111849.

[5] PATANAIK A, ONG J L, GOOLEY J J, et al. An end-to-end framework for real-time automatic sleep stage classification [J]. Sleep, 2018, 41(5): zsy041.

[6] PHAN H, ANDREOTTI F, COORAY N, et al. SeqSleepNet: end-to-end hierarchical recurrent neural network for sequence-to-sequence automatic sleep staging [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2019, 27(3): 400-410.

[7] PERSLEV M, JENSEN M H, DARKNER S, et al. U-Time: a fully convolutional network for time series segmentation applied to sleep staging [C]// Proceedings of the 33rd International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2019: 4415-4426.

[8] JIA Ziyu, LIN Youfang, WANG Jing, et al. SalientSleepNet: multimodal salient wave detection network for sleep staging [C]// Proceedings of the 30th International Joint Conference on Artificial Intelligence. San Mateo, CA, USA: Morgan Kaufmann, 2021: 2614-2620.

[9] WEI Yuhui, QI Xia, WANG Huaning, et al. A multi-class automatic sleep staging method based on long short-term memory network using single-lead electrocardiogram signals [J]. IEEE Access, 2019, 7: 85959-85970.

[10] SUPRATAK A, DONG Hao, WU Chao, 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.

[11] SUPRATAK A, GUO Yike. TinySleepNet: an efficient deep learning model for sleep stage scoring based on raw single-channel EEG [C]// Proceedings of the 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). Piscataway, NJ, USA: IEEE, 2020: 641-644.

[12] KORKALAINEN H, AAKKO J, NIKKONEN S, et

- al. Accurate deep learning-based sleep staging in a clinical population with suspected obstructive sleep apnea [J]. *IEEE Journal of Biomedical and Health Informatics*, 2020, 24(7): 2073-2081.
- [13] QU Wei, WANG Zhiyong, HONG Hong, et al. A residual based attention model for EEG based sleep staging [J]. *IEEE Journal of Biomedical and Health Informatics*, 2020, 24(10): 2833-2843.
- [14] ZHOU Jinjin, WANG Guangsheng, LIU Junbiao, et al. Automatic sleep stage classification with single channel EEG signal based on two-layer stacked ensemble model [J]. *IEEE Access*, 2020, 8: 57283-57297.
- [15] JIANG Dihong, LU Yanan, MA Yu, et al. Robust sleep stage classification with single-channel EEG signals using multimodal decomposition and HMM-based refinement [J]. *Expert Systems with Applications*, 2019, 121: 188-203.
- [16] WACKER W, WITTE H. Time-frequency techniques in biomedical signal analysis [J]. *Methods of Information in Medicine*, 2013, 52(4): 279-296.
- [17] 胡勤伟, 陶庆, 王妮妮, 等. 用于稳态视觉诱发电位目标识别的多尺度特征融合卷积神经网络方法 [J]. *西安交通大学学报*, 2022, 56(4): 185-193, 202.
- HU Qinwei, TAO Qing, WANG Nini, et al. A multi-scale feature fusion convolutional neural network approach for steady-state visual evoked potential target recognition [J]. *Journal of Xi'an Jiaotong University*, 2022, 56(4): 185-193, 202.
- [18] 邵舒羽, 吴锦涛, 周前祥, 等. 睡眠-觉醒节律紊乱下注意诱发脑电特征分析与识别 [J]. *航天医学与医学工程*, 2021, 34(6): 439-447.
- SHAO Shuyu, WU Jintao, ZHOU Qianxiang, et al. EEG characteristics analysis and recognition induced by attention under sleep-wake rhythm disorder [J]. *Space Medicine & Medical Engineering*, 2021, 34(6): 439-447.
- [19] SIMONYAN K, ZISSERMAN A. Very Deep convolutional networks for large-scale image recognition [C] // *Proceedings of the 3rd International Conference on Learning Representations*. Amherst, Massachusetts, USA: OpenReview, 2015: 1-14.
- [20] BERRY R B. *Fundamentals of sleep medicine* [M]. Philadelphia, USA: Elsevier/Saunders, 2012.
- [21] 陈保家, 陈学力, 沈保明, 等. CNN-LSTM 深度神经网络在滚动轴承故障诊断中的应用 [J]. *西安交通大学学报*, 2021, 55(6): 28-36.
- CHEN Baojia, CHEN Xueli, SHEN Baoming, et al. An application of convolution neural network and long short-term memory in rolling bearing fault diagnosis [J]. *Journal of Xi'an Jiaotong University*, 2021, 55(6): 28-36.
- [22] SCHUSTER M, PALIWAL K K. Bidirectional recurrent neural networks [J]. *IEEE Transactions on Signal Processing*, 1997, 45(11): 2673-2681.
- [23] ZHANG Guoqiang, CUI Licong, MUELLER R, et al. The national sleep research resource: towards a sleep data commons [J]. *Journal of the American Medical Informatics Association*, 2018, 25(10): 1351-1358.
- [24] QUAN S F, HOWARD B V, IBER C, et al. The sleep heart health study: design, rationale, and methods [J]. *Sleep*, 1997, 20(12): 1077-1085.
- [25] ROY Y, BANVILLE H, ALBUQUERQUE I, et al. Deep learning-based electroencephalography analysis: a systematic review [J]. *Journal of Neural Engineering*, 2019, 16(5): 051001.
- [26] SUN Chenglu, FAN Jiahao, CHEN Chen, et al. A two-stage neural network for sleep stage classification based on feature learning, sequence learning, and data augmentation [J]. *IEEE Access*, 2019, 7: 109386-109397.

(编辑 武红江 刘杨)