



基于双向LSTM卷积网络与注意力机制的自动睡眠分期模型

李倩玉, 王蓓, 金晶, 张涛, 王行愚

引用本文:

李倩玉, 王蓓, 金晶, 张涛, 王行愚. 基于双向LSTM卷积网络与注意力机制的自动睡眠分期模型[J]. 智能系统学报, 2022, 17(3): 523–530.

LI Qianyu, WANG Bei, JIN Jing, ZHANG Tao, WANG Xingyu. Automatic sleep staging model based on the bi-directional LSTM convolutional network and attention mechanism[J]. *CAAI Transactions on Intelligent Systems*, 2022, 17(3): 523–530.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202103013>

您可能感兴趣的其他文章

层次化双注意力神经网络模型的情感分析研究

Hierarchical double-attention neural networks for sentiment classification

智能系统学报. 2020, 15(3): 460–467 <https://dx.doi.org/10.11992/tis.201812017>

基于注意力融合的图片描述生成方法

An image caption generation method based on attention fusion

智能系统学报. 2020, 15(4): 740–749 <https://dx.doi.org/10.11992/tis.201910039>

基于注意力机制的显著性目标检测方法

Salient object detection method based on the attention mechanism

智能系统学报. 2020, 15(5): 956–963 <https://dx.doi.org/10.11992/tis.201903001>

基于双向消息链路卷积网络的显著性物体检测

Salient object detection based on bidirectional message link convolution neural network

智能系统学报. 2019, 14(6): 1152–1162 <https://dx.doi.org/10.11992/tis.201812003>

深度学习的双人交互行为识别与预测算法研究

Human interaction recognition and prediction algorithm based on deep learning

智能系统学报. 2020, 15(3): 484–490 <https://dx.doi.org/10.11992/tis.201812029>

注意力机制和Faster RCNN相结合的绝缘子识别

Insulator recognition based on attention mechanism and Faster RCNN

智能系统学报. 2020, 15(1): 92–98 <https://dx.doi.org/10.11992/tis.201907023>

微信公众平台



关注微信公众号，获取更多资讯信息

DOI: 10.11992/tis.202103013

网络出版地址: <https://kns.cnki.net/kcms/detail/23.1538.TP.20211202.0158.002.html>

基于双向 LSTM 卷积网络与注意力机制的自动睡眠分期模型

李倩玉¹, 王蓓¹, 金晶¹, 张涛², 王行愚¹

(1. 华东理工大学 信息科学与工程学院, 上海 200237; 2. 清华大学 自动化系, 北京 100086)

摘要: 针对现阶段深度睡眠分期模型存在的梯度消失、对时序信息学习能力较弱等问题, 提出一种基于双向长短时记忆卷积网络与注意力机制的自动睡眠分期模型。将少样本类别的睡眠脑电数据通过过采样方式进行数据增强后, 利用带残差块的卷积神经网络学习数据特征表示, 再通过带注意力层的双向长短时记忆网络挖掘深层时序信息, 使用 Softmax 层实现睡眠分期的自动判别。实验使用 Sleep-EDF 数据集中 19 晚单通道脑电信号对模型进行交叉验证, 取得了较高的分类准确率和宏平均 F_1 值, 优于对比方法。该方法能够有效缓解睡眠分期判别中少数类分类性能较低的问题, 并提高了深度睡眠分期模型的整体分类性能。

关键词: 睡眠分期; 脑电图; 卷积神经网络; 残差网络; 双向长短时记忆网络; 注意力机制; 类不平衡; 过采样
中图分类号: TP391.4 **文献标志码:** A **文章编号:** 1673-4785(2022)03-0523-08

中文引用格式: 李倩玉, 王蓓, 金晶, 等. 基于双向 LSTM 卷积网络与注意力机制的自动睡眠分期模型 [J]. 智能系统学报, 2022, 17(3): 523-530.

英文引用格式: LI Qianyu, WANG Bei, JIN Jing, et al. Automatic sleep staging model based on the bi-directional LSTM convolutional network and attention mechanism[J]. CAAI transactions on intelligent systems, 2022, 17(3): 523-530.

Automatic sleep staging model based on the bi-directional LSTM convolutional network and attention mechanism

LI Qianyu¹, WANG Bei¹, JIN Jing¹, ZHANG Tao², WANG Xingyu¹

(1. School of Information Science and Engineering, East China University of Science and Technology, Shanghai 200237, China;

2. Department of Automation, Tsinghua University, Beijing 100086, China)

Abstract: Owing to the problems of gradient disappearance and the weak learning ability of time series information in the current deep sleep staging model, we propose an automatic sleep staging model based on the bi-directional long short-term memory convolutional network and attention mechanism. After the sleep EEG data of minority classes are enhanced by oversampling, a convolutional neural network with a residual block is designed to learn the data feature representation, and then, an attention layer is combined with the BiLSTM network to extract the deep time sequence information, a softmax layer is adopted to realize the automatic discrimination of sleep stages. A total of 19-night single-channel EEG signals from the Sleep-EDF dataset are analyzed to cross-verify the proposed model. The obtained classification accuracy and macro- F_1 -score (MF_1) are more satisfied than the comparison methods. The effect of low classification performance of minority classes in sleep staging is reduced effectively. The overall classification performance by the proposed deep sleep staging model is sufficiently improved.

Keywords: sleep staging; electroencephalogram; convolutional neural network; residual network; Bi-directional long short-term memory network; attention mechanism; class imbalance; oversampling

睡眠是人的一生中不可缺少的一种复杂生理

过程。充足的睡眠能使大脑和身体得到充分的休息和恢复。由于如今不健康的生活方式的影响, 睡眠障碍已成为现代社会的严重问题。长时间的睡眠障碍会使人精神不振、免疫力下降, 还会诱

收稿日期: 2021-03-08. 网络出版日期: 2021-12-03.

基金项目: 国家自然科学基金项目(61773164); 上海市自然科学基金项目(16ZR1407500).

通信作者: 王蓓, E-mail: beiwang@ecust.edu.cn.

发心脑血管疾病等^[1]。因此,及早诊断睡眠障碍有助于发现异常变化并防止疾病进一步发展,对身心健康具有重要的意义。

睡眠分期是诊断睡眠障碍和检测睡眠质量的有效方式。在实际临床上,首先利用多导睡眠监测仪(polysomnography, PSG)获取脑电、眼电、肌电、脉搏、血氧饱和度、呼吸等信号,再由专业医师对照国际通用的睡眠分期标准^[2-4],对每个 30 s 时长的睡眠数据进行睡眠时期的人工划分。研究表明,睡眠深浅的变化是由神经中枢活动的变化引起的,因此综合上述信号在不同睡眠时期的特征,能够很好地反映睡眠模式^[5-6]。然而,整晚的睡眠数据量较大,对专业医师的资质要求高,人工判读烦琐且耗时。随着大数据、人工智能等新技术的发展,自动睡眠分期方法逐渐成为快捷的辅助方式,受到了广泛的研究与关注^[7]。

近年来,自动睡眠分期方法主要涵盖了基于机器学习和深度学习的方法。基于机器学习的自动睡眠分期方法通常包含了特征提取和睡眠阶段分类两个步骤。通过时域分析法^[8-9]、频域分析法^[10-11]等来提取睡眠特征,捕获睡眠过程中的主要变化,然后采用如随机森林^[12-13]、支持向量机^[14-15]等分类器对睡眠阶段进行分类。基于深度学习的自动睡眠分期方法主要依靠深度神经网络端对端特性,自动提取复杂、有用的特征,从一定程度上避免了手工提取特征的主观性。然后,通过深化网络结构、堆叠不同功能网络层的方式,提高网络的特征表达能力。深度学习模型能够利用损失函数衡量网络输出与实际标签的偏差,并借助反向传播算法计算损失成本关于参数的梯度,以此来不断更新各层参数,从而得到最佳的分类输出。

相比于机器学习的处理模式,深度学习模型在自动特征提取和模型优化上均具有一定的优势。常见的卷积神经网络最先在自动睡眠分期上获得广泛的应用。例如:Tsinalis 等^[16]使用未经预处理的原始脑电信号作为输入,在两个卷积层中分别利用大小不同的卷积核,提取信号不同尺度上的抽象特点,丰富了信号的特征表示;Zhao 等^[17]利用多层卷积及映射模块提取并融合了脑电图和心电图中的多尺度特征,对不同睡眠阶段相关信号的细微变化进行捕捉;Sors 等^[18]则利用当前待分类的数据段及其前后两个数据段作为输入,构建了一个 14 层卷积神经网络。

此外,考虑到睡眠过程中所获取的脑电数据具有时间序列的特点,适用于时间序列分类的递归神经网络^[19-20](recursive neural network, RNN)、

长短时记忆网络^[21-23](long short-term memory, LSTM)、双向长短时记忆网络^[24-25](bi-directional long short-term memory, BiLSTM)等相继被应用在了睡眠分期问题上。例如:Hsu 等^[19]利用 Elman 递归神经网络同时提供信号流前馈连接和反馈连接通道,便于捕捉睡眠前后关联信息;杨鑫等^[20]提出了一种基于双向递归神经网络的单通道睡眠分期方法,融入了双向递归神经网络对前后时序信号的记忆能力,提高了睡眠分期判别的准确率;Dong 等^[23]利用整流神经网络检测分层特征,并利用长短时记忆网络进行序列信息学习,以优化分类性能;罗森林等^[24]将卷积神经网络与双向长短时记忆网络结合,综合利用这两种网络的优点,实现睡眠时期的自动判别。

虽然目前基于深度学习的自动睡眠分期方法已取得了不错的效果,但仍存在几个比较突出的问题:1)虽然深度学习可以通过不断加深网络结构来获得输入信号的更有效的特征表达,但一个层级过深的神经网络往往会存在梯度消失的问题;2)在睡眠分期任务上效果较好的双向长短时记忆网络尚不能在一个长序列中突出重要的信息,进而削弱了网络对时序信息的学习能力;3)由于不同睡眠时期样本之间存在明显的不平衡问题,不可避免地会影响到自动睡眠分期模型在少样本类别上的分类性能,从而降低了整体的分类效果。

综合考虑上述问题,在构建睡眠分期的深度学习模型中,本文提出了一种基于双向 LSTM 卷积网络与注意力机制(CNN-BiLSTM-Attention)的自动睡眠分期模型。首先,利用卷积神经网络(convolution neural network, CNN)从原始脑电信号中提取时不变特征,并引入残差网络,避免网络结构过深带来的梯度消失问题;其次,针对睡眠脑电数据的前后序列相关性,设计了带注意力机制(Attention)的双向长短时记忆网络(BiLSTM),来加强对时序信息的学习,以提升睡眠分期方法的分类性能;同时,采用过采样方法,对睡眠过渡阶段(少样本类别)进行数据增强处理,以减轻样本不平衡问题对模型带来的影响。

1 模型框架

本文所设计并构建的基于双向 LSTM 卷积网络与注意力机制的自动睡眠分期模型结构如图 1 所示。该 CNN-BiLSTM-Attention 模型主要由 4 个模块组成:数据输入模块、特征表示模块、序列信息学习模块以及分类判别模块。

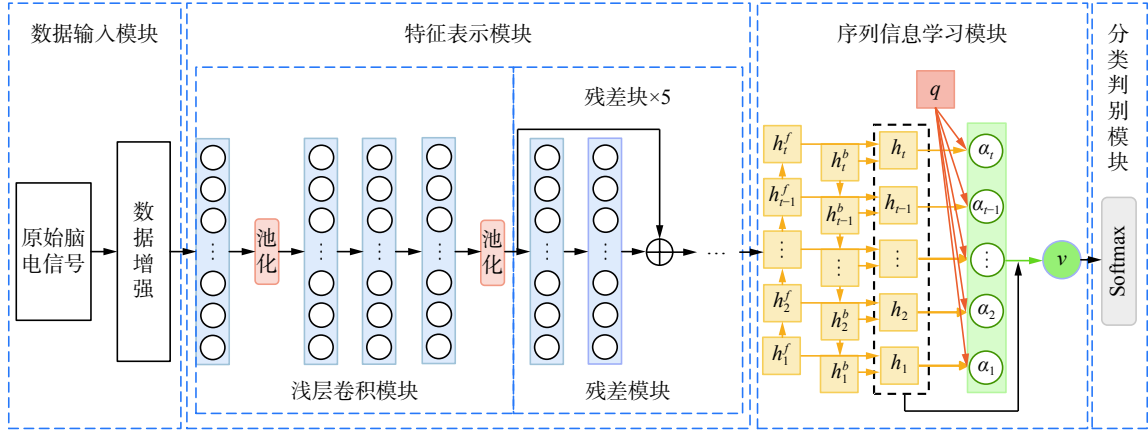


图 1 基于 CNN-BiLSTM-Attention 的自动睡眠分期模型

Fig. 1 Automatic sleep staging model based on CNN-BiLSTM-Attention

1.1 数据增强处理

自动睡眠分期以临床采集的受试者整夜睡眠产生的生物电信号作为输入。在一个正常人的整晚睡眠中,不同睡眠时期的时长占比存在较大差异,导致了少样本睡眠阶段分类性能表现较差的问题。

为解决样本不平衡问题,在数据输入模块中,本文采用了边界人工合成少数类过采样算法(borderline synthetic minority oversampling technique, Borderline SMOTE)对原始脑电信号进行数据增强处理。该算法是常用过采样技术的改进算法^[26],它将少数类样本分为安全、危险和噪声 3 类,并仅使用代表在少数类样本边界上的危险样本来合成新的数据,以达到样本平衡效果。利用该算法生成样本步骤:

1) 对每个少数类样本 p_i , 利用 K 近邻算法从整个数据集中计算其 m 个最近邻;

2) 将周围 m 个最近邻样本有一半以上为少数类样本的定义为安全样本,周围 m 个最近邻样本有一半以上为多数类样本的定义为危险样本,周围 m 个最近邻样本均为多数类样本的定义为噪声样本;

3) 对于每个危险样本 d_i , 从其 k 个最近邻中随机选择 s 个最近邻,在这 s 个最近邻样本和原危险样本之间随机合成 n 个新样本,计算公式为

$$d_{ni} = d_i + \text{rand}(0, 1) \times (d_{si} - d_i) \quad (1)$$

1.2 CNN 特征表示

在深度学习中,常常在网络前端构建多个具有不同大小卷积核的卷积层提取输入信号的局部或全局特征,从而得到输入数据的有效描述。一般来说,卷积层越多,网络往往能获得更大的感受野,并提取出更好的特征。但实践证明,网络结构的加深会使梯度爆炸、梯度消失的风险增加。

为了提取更有效的特征避免梯度消失的风

险,本文在网络架构中加入了残差网络。如图 1 特征表示模块所示,在特征表示层构建了一个 16 层卷积神经网络。该卷积神经网络由浅层卷积模块与残差模块两部分组成。浅层卷积模块将增强后的数据作为输入,依次通过 1×50 大卷积核层、 1×8 最大池化层、3 个 1×8 小卷积核层以及 1×4 最大池化层,提取输入数据的低级特征,然后将得到的低级特征输入给残差模块。残差模块部分共包括 5 个相同的残差块,本文设计的残差块结构如图 2 所示。

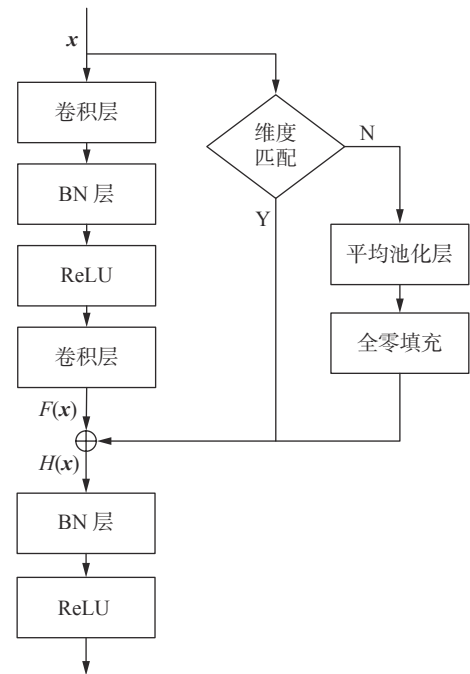


图 2 残差块结构

Fig. 2 Residual block structure

残差块与普通卷积神经网络的不同之处在于,它在一般卷积层外增加了跳跃结构。假定网络的输入为 x , 输入经卷积后运算结果为 $F(x)$, 残差块输出为 $H(x)$ 。若 x 与 $F(x)$ 维度匹配,则有

$$H(x) = f(F(x) + x) \quad (2)$$

若 x 与 $F(x)$ 维度不匹配,则在跳跃结构添加平均池化层与全零填充层,利用全零填充增加输入维度,使得跳跃结构的输出与 $F(x)$ 维度适配。

1.3 序列信息学习

对于睡眠分期任务来说,作为输入的睡眠脑电信号是一段连续的具有强相关性的时间序列,需要网络具有一定的“记忆功能”,综合前后信息对当前睡眠时期作出判断。卷积神经网络的输入是一个独立的、没有上下文联系的单元,在处理输入是具有明显上下文关系的序列化信号时不占优势。

为了解决上述问题,本文在特征表示模块后,加入了 BiLSTM 结构和注意力机制,以帮助网络进行序列信息学习。如图 1 中的序列信息学习模块所示,将 BiLSTM 层与注意力层级联, BiLSTM 层的输出是注意力层的输入。

BiLSTM 层: BiLSTM 是将两个方向不同的独立的 LSTM 结构叠加在一起而组成的,一个为前向层,另一个为反向层。在每一个时刻 t , 输入 x_t 同时提供给这两个层,在前向层从 1 时刻到 t 时刻正向计算一遍,得到并保存每个时刻向前隐含层的输出 h_{fw} 。在反向层沿着时刻 t 到时刻 1 反向计算一遍,得到并保存每个时刻向后隐含层的输出 h_{bw} 。最后,在每个时刻结合前向层和反向层输出结果得到最终的输出 h_t 。

$$h_t = f(h_{fw}, h_{bw}) \quad (3)$$

注意力层: BiLSTM 不能在一个长序列中突出重要的信息,削弱了网络对时序信息的学习能力。而注意力机制恰恰能弥补这一缺点。注意力机制可以通过引入新的可训练变量,依次加强各段数据之间的联系,突出注意力集中的数据段帮助网络捕获阶段信息。

对于 t 时刻 BiLSTM 层的输出 h_t , 初始化查询向量 q , 利用点积模型计算注意力层输入 h_t 与查询向量 q 之间的相似度,通过相似度对比得出各输出数据段的重要程度,得到注意力得分 $f_{score}(h_t, q)$ 。然后利用归一化指数 (Softmax) 函数将注意力得分转换为 $[0, 1]$ 之间的概率分布,得到权重系数 α_t , 根据权重系数对输入 h_t 进行加权求和,得到注意力层输出 v 。具体计算如下:

$$f_{score}(h_t, q) = h_t^T q \quad (4)$$

$$\alpha_t = \frac{\exp(f_{score}(h_t, q))}{\sum_i \exp(f_{score}(h_i, q))} \quad (5)$$

$$v = \sum_t \alpha_t h_t \quad (6)$$

1.4 分类判别

最后,将利用注意力机制求得的特征表示 v 利用 Softmax 函数分类,得到当前输入样本的睡眠时期预测分布 P 。Softmax 函数是深度学习中常用且有效的分类器,计算公式为

$$P = \text{Softmax}(Wv + b) \quad (7)$$

式中 W 和 b 分别为 Softmax 层的权重和偏置。

2 实验分析

2.1 实验数据集

本文使用了来自 PhysioNet 数据库中的 Sleep-EDF 数据集^[27]。该数据集包含 197 个整夜睡眠的生物电信号。数据集中的数据由睡眠专家按照 R&K 规则划分为: 清醒期 (W)、非快速眼动睡眠 I 期 (S1)、II 期 (S2)、III 期 (S3)、IV 期 (S4)、快速眼动期 (REM)、身体运动时间阶段和无法判读的阶段。选取了年龄为 25~33 岁的女性被试者身上采集的 19 个整晚单通道 (Pz-Oz) 睡眠脑电数据, 采样频率为 100 Hz。对上述数据做了如下调整: 1) 去除原数据集中身体运动时间阶段和无法判读的阶段; 2) 考虑到 S3、S4 时期都属于深度睡眠时期, 其数据特征也较相似, 因此将 S3 和 S4 期合并为 SS 期。调整后的数据用于模型的训练、验证与测试, 得到 5 个睡眠时期的判别结果 (W、REM、S1、S2 和 SS)。

将 30 s 时长的脑电数据作为一个样本, 从原始数据集中总计提取到 18816 个样本。根据已知的睡眠分期人工标签, 统计了不同睡眠时期的样本数量占比, 其中 S2 占比 44.80%, REM 时期占比 18.25%, SS 时期占比 15.77%, W 时期占比 12.63%, S1 时期占比 8.55%。相比于 S2, 属于睡眠过渡阶段的 S1 的占比明显偏少, 其余睡眠时期略有差异。采用 1.1 节中的 Borderline SMOTE, 对少数类样本进行了数据增强处理, 使得各睡眠时期之间的样本数量占比均衡。经过类平衡处理后的样本总量为 42145。

2.2 实验设置与评价指标

本文采用七折交叉验证来评估模型性能, 使用 RMSProp 优化器来调整权重, 学习速率和衰减系数分别设置为 0.0001 和 0.9。为了探究模型对原始数据的分类性能, 本文利用序号编码, 在开始训练前即给数据添加编号, 然后打乱数据。将数据分为 7 折, 每次以其中 6 折作为训练集, 1 折作为测试集, 共计进行 7 次实验, 得到模型对全部数据的预测结果。再将预测标签按原来编号顺序重排, 得到

模型对真实睡眠脑电数据的睡眠分期预测结果。

为了评估所构建的模型的分类效果,本文计算了各睡眠时期的精确率(p)、召回率(r)和 F_1 值(F_1)以及整体睡眠分期的平均准确率和宏平均 F_1 值(MF_1)。

2.3 实验结果与分析

2.3.1 混淆矩阵

表 1 和表 2 分别给出了两种模型的混淆矩阵。混淆矩阵涵盖了自动睡眠分期结果与已知的人工标签相比较得到的统计结果。表 1、2 中,行代表已知的人工标签,列是模型得到的预测结果,对角线上粗体的数字为两者判断相一致的样本数量。表 1 给出了采用原始睡眠脑电数据,基于常用的 CNN-LSTM 自动睡眠模型得到的混淆矩阵;表 2 给出了采用经类平衡处理后的数据,基于 CNN-BiLSTM-Attention 自动睡眠模型得到的混淆矩阵(该结果仅包含真实的睡眠脑电数据,生成数据不包含在内)。

表 1 原始数据集下 CNN-LSTM 模型的混淆矩阵

Table 1 Confusion matrix of CNN-LSTM model under the original data set

标签	预测结果					性能指标/%		
	SS	S2	S1	REM	W	p	r	F_1
SS	2 317	631	4	7	9	87.07	78.07	82.32
S2	329	7457	112	508	23	85.40	88.47	86.91
S1	3	323	409	663	211	45.34	25.42	32.58
REM	2	282	128	3 006	15	69.94	87.56	77.76
W	10	39	249	114	1 965	88.39	82.67	85.43

注:平均准确率为80.54%

表 2 类平衡后 CNN-BiLSTM-Attention 模型的混淆矩阵

Table 2 Confusion matrix of CNN-BiLSTM-Attention model after class balance

标签	预测结果					性能指标/%		
	SS	S2	S1	REM	W	p	r	F_1
SS	2601	354	3	8	2	86.10	87.63	86.86
S2	417	7292	225	467	28	92.23	86.51	89.28
S1	2	83	1336	132	56	76.34	83.03	79.55
REM	0	165	134	3111	23	83.14	90.62	86.72
W	1	12	52	24	2288	95.45	96.26	95.85

注:平均准确率为88.37%

比较表 1 和表 2,可以观察到,本文提出的自动睡眠分期模型取得了令人满意的总体分类性能,分类准确率达到 88.37%,相比 CNN-LSTM 模型提升了近 8%。在原始睡眠脑电数据集中,属于睡眠过渡阶段的 S1 的样本数量占比极小。在表 1 中,S1 的精确率为 45.34%,召回率为 25.42%,反

映综合性能的 F_1 指数仅为 32.58%。经过类平衡处理后,S1 的分类性能得到了显著提高。在表 2 中,S1 的精确率和召回率分别提高到至 76.34% 和 83.03%, F_1 指数也达到了 79.55%,体现了类平衡处理的必要性和有效性。同时,其他睡眠分期的判别效果均有不同程度的提升,其中 W 的 3 项性能指标都在 95% 以上,S2、SS 和 REM 的各项性能指标也都在 80% 以上。从上述分类结果中可以看出,CNN-BiLSTM-Attention 模型明显优于常用的 CNN-LSTM 模型,体现了本文在模型结构上所作的改进能够有效提高模型在不同睡眠分期上的分类效果。

2.3.2 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。本文通过序列编码的方式,既能够保证模型训练时有类间较平衡的样本数量,也能够从自动判别结果中快捷地获取原始数据的睡眠分期判别结果,得到整晚睡眠的时相序列图,展示睡眠状态随时间变化的结果,为临床的诊断与治疗提供重要依据。

图 3 和图 4 是同一名受试者整晚睡眠的时相序列图,其中图 3 为睡眠分期的人工判别结果,图 4 为本文所提出的自动睡眠分期模型的判别结果。从图 4 可以观察到,该模型对于持续的清醒状态有较好的判别效果,对睡眠过程中出现的短时觉醒现象也能做到较准确的预测。整晚睡眠过程是一个连续过程,相邻睡眠状态之间的特征较相似,模型在部分相邻状态 S2 和 S3 以及 S1 和 S2、REM 存在一定的混淆。整体上,模型得到的睡眠状态的变化趋势与人工标签大体相一致,能够为临床诊断提供有效的辅助判别。




图 3 临床专家手动判断结果

Fig. 3 Manual inspection results by clinical experts




图 4 基于 CNN-BiLSTM-Attention 的自动睡眠分期模型的判断结果

Fig. 4 Interpretation results based on CNN-BiLSTM-Attention automatic sleep staging model

2.3.3 与其他方法的比较

为进一步验证模型中引入的 BiLSTM 模块与注意力机制的有效性, 首先进行了消融实验, 将模型中的 BiLSTM-Attention 结构分别替换成了 LSTM 块和 BiLSTM 块, 结果如表 3 中第 1、2 行所示。与本文所提出的 CNN-BiLSTM-Attention 模型进行对比后, 从中可以看到, 在不使用 BiLSTM 模块和注意力机制时, 模型的总体分类准确率及各睡眠分期的 F_1 都会有不同程度的下降。特别是 S1 阶段的分类性能下降的最为明显。这样的结果验证了本文所提出模型的有效性以及注意力机制在学习睡眠分期转换规律上的重要性。

其次, 与采用相同数据集和脑电信号通道的部分文献中自动睡眠分期判别结果进行了比较。如表 3 中第 3、4、5 行所示, 所比较的 3 个模型均属于基于深度学习的自动睡眠分期模型。其中, 文献 [28] 提出了一个 DeepSleepNet 的网络架构, 利用 CNN 自动提取特征, 堆叠 BiLSTM 架构学习睡眠转换规则; 文献 [29] 提出了一种序列深度模型; 文献 [30] 提出了一个结合状态转移规则的深度睡眠分期模型。从表 3 中可以看出, 相比上述文献中的模型, 本文所提出的 CNN-BiLSTM-Attention 模型分类准确率有 5.5%~8.5% 的提高, 且 MF_1 提高了 10% 以上。

表 3 基于 CNN-BiLSTM-Attention 的自动睡眠分期模型和其他分类方法的比较

Table 3 Comparison of automatic sleep staging model based on CNN-BiLSTM-Attention and other classification methods

方法	数据集	脑电通道	测试集数量	准确率/%	MF_1 /%	F_1 /%				
						W	REM	S1	S2	SS
CNN-LSTM	Sleep-EDF	Pz-Oz	18816	83.58	81.62	93.20	82.63	61.35	86.13	84.71
CNN-BiLSTM	Sleep-EDF	Pz-Oz	18816	83.92	82.30	93.86	83.27	64.20	86.02	84.14
文献[28]	Sleep-EDF	Pz-Oz	41950	79.80	73.10	88.10	80.30	37.00	82.70	77.30
文献[29]	Sleep-EDF	Pz-Oz	42308	82.83	77.02	90.27	82.88	44.64	85.74	81.55
文献[30]	Sleep-EDF	Pz-Oz	17764	82.30	74.18	86.90	81.30	31.50	87.20	84.00
CNN-BiLSTM-Attention	Sleep-EDF	Pz-Oz	18816	88.37	87.65	95.85	86.72	79.55	89.28	86.86

3 结束语

本文提出了一种基于 CNN-BiLSTM-Attention 的自动睡眠分期模型。该模型利用卷积神经网络作为特征提取器, 从原始单通道脑电信号提取时不变特征, 同时引入残差网络架构, 在加深网络层次的同时避免网络出现梯度消失问题, 并利用带注意力机制的 BiLSTM 进一步学习输入信号的时序信息, 挖掘睡眠过程的转换机制。通过交叉验证、消融实验, 以及与相关文献方法的对比, 表明本文所提出的模型在睡眠分期判读的精度上和综合判别性能上, 均具有优势, 能够为睡眠过程监测、诊断与治疗提供有效可行的辅助判别工具。此外, 本文的研究工作主要基于单通道的睡眠脑电信号, 在此基础上可加入其他电生理信号(如眼电和肌电等), 基于更加丰富的信号来源, 利用该模型进行自动睡眠分期判别的研究。

参考文献:

- [1] LUYSTER F S, STROLLO P J, ZEE P C, et al. Sleep: a health imperative[J]. *Sleep*, 2012, 35(6): 727-734.
- [2] IBER C, ANCOLI-ISRAEL S, CHESSON A L, et al. The AASM manual for the scoring of sleep and associated events: rules, terminology and technical specifications [M]. Westchester, IL: American Academy of Sleep Medicine, 2007.
- [3] RECHTSCHAFFEN A, KALES A. A manual of standardized terminology: techniques and scoring system of sleep stages of human subjects[M]. Los Angeles: UCLA Brain Information Service/Brain Research Institute, 1968.
- [4] BERRY R B, BUDHIRAJA R, GOTTLIEB D J, et al. Rules for scoring respiratory events in sleep: update of the 2007 AASM manual for the scoring of sleep and associated events[J]. *Journal of clinical sleep medicine*, 2012, 8(5): 597-619.
- [5] KARSON C N. Brainstem control of wakefulness and sleep[J]. *American journal of psychiatry*, 1991, 148(7): 944.
- [6] ROEBUCK A, MONASTERIO V, GEDERI E, et al. A

- review of signals used in sleep analysis[J]. *Physiological measurement*, 2014, 35(1): R1–R57.
- [7] FAUST O, RAZAGHI H, BARIKA R, et al. A review of automated sleep stage scoring based on physiological signals for the new millennia[J]. *Computer methods and programs in biomedicine*, 2019, 176: 81–91.
- [8] DIYKH M, LI Yan, WEN Peng. EEG sleep stages classification based on time domain features and structural graph similarity[J]. *IEEE transactions on neural systems & rehabilitation engineering*, 2016, 24(11): 1159–1168.
- [9] EBRAHIMI F, SETAREHDAN S K, NAZERAN H. Automatic sleep staging by simultaneous analysis of ECG and respiratory signals in long epochs[J]. *Biomedical signal processing and control*, 2015, 18(4): 69–79.
- [10] DIMITRIADIS S I, SALIS C, LINDEN D. A novel, fast and efficient single-sensor automatic sleep-stage classification based on complementary cross-frequency coupling estimates[J]. *Clinical neurophysiology*, 2018, 129(4): 815–828.
- [11] DA SILVEIRA T L T, KOZAKEVICIUS A J, RODRIGUES C R. Single-channel EEG sleep stage classification based on a streamlined set of statistical features in wavelet domain[J]. *Medical and biological engineering and computing*, 2017, 55(2): 343–352.
- [12] LAJNEF T, CHAIBI S, RUBY P, et al. Learning machines and sleeping brains: Automatic sleep stage classification using decision-tree multi-class support vector machines[J]. *Journal of neuroscience methods*, 2015, 250: 94–105.
- [13] LIU Junbiao, WU Duanpo, WANG Zimeng, et al. Automatic sleep staging algorithm based on random forest and hidden markov model[J]. *CMES—computer modeling in engineering and sciences*, 2020, 123(1): 401–426.
- [14] ALICKOVIC E, SUBASI A. Ensemble SVM method for automatic sleep stage classification[J]. *IEEE transactions on instrumentation and measurement*, 2018, 67(6): 1258–1265.
- [15] BASHA A J, BALAJI B S, POORNIMA S, et al. Support vector machine and simple recurrent network based automatic sleep stage classification of fuzzy kernel[J]. *Journal of ambient intelligence and humanized computing*, 2021, 12(6): 6189–6197.
- [16] TSINALIS O, MATTHEWS P M, GUO Yike, et al. Automatic sleep stage scoring with single-channel EEG using convolutional neural networks[EB/OL]. (2016–10–05)[2021–03–08] <https://arxiv.org/abs/1610.01683>.
- [17] ZHAO Ranqi, XIA Yi, WANG Qiuyang. Dual-modal and multi-scale deep neural networks for sleep staging using EEG and ECG signals[J]. *Biomedical signal processing and control*, 2021, 66: 102455.
- [18] SORS A, BONNET S, MIREK S, et al. A convolutional neural network for sleep stage scoring from raw single-channel EEG[J]. *Biomedical signal processing and control*, 2018, 42: 107–114.
- [19] HSU Y L, YANG Yating, WANG J S, et al. Automatic sleep stage recurrent neural classifier using energy features of EEG signals[J]. *Neurocomputing*, 2013, 104: 105–114.
- [20] 杨鑫, 吴之南, 钱松荣. 基于双向递归神经网络的单通道脑电图睡眠分期研究 [J]. *微型电脑应用*, 2017, 33(1): 42–45.
- YANG Xin, WU Zhinan, QIAN Songrong. Study on sleep staging based on bidirectional recurrent neural network in single channel EEG[J]. *Microcomputer applications*, 2017, 33(1): 42–45.
- [21] 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.
- [22] CASCIOLA A A, CARLUCCI S K, KENT B A, et al. A deep learning strategy for automatic sleep staging based on two-channel EEG headband data[J]. *Sensors*, 2021, 21(10): 3316.
- [23] DONG Hao, SUPRATAK A, PAN Wei, et al. Mixed neural network approach for temporal sleep stage classification[J]. *IEEE transactions on neural systems and rehabilitation engineering*, 2018, 26(2): 324–333.
- [24] 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.
- LUO Senlin, HAO Jingwei, PAN Limin. An automatic sleep staging method based on CNN-BiLSTM[J]. *Transactions of Beijing Institute of Technology*, 2020, 40(7): 746–752.
- [25] CHEN Xueyan, HE Jie, WU Xiaoqiang, et al. Sleep staging by bidirectional long short-term memory convolution neural network[J]. *Future generation computer systems*, 2020, 109: 188–196.
- [26] HAN Han, WANG Wenyuan, MAO Binghuan. Borderline-SMOTE: a new over-sampling method in imbal-


- anced data sets learning[C]//International Conference on Intelligent Computing. Fuzhou: Springer, 2015: 878–887.
- [27] GOLDBERGER A L, AMARAL L A, 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.
- [28] SUPRATAK A, DONG Hao, WU Chao, et al. Deep SleepNet: 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.
- [29] 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): e0216456.
- [30] 马家睿, 王蓓, 金晶, 等. 结合状态转移规则的深度睡眠分期模型 [J]. *计算机工程与设计*, 2020, 41(10): 2878–2883.
- MA Jiarui, WANG Bei, JIN Jing, et al. Deep automatic sleep staging model integrated with state transition

rules[J]. *Computer engineering and design*, 2020, 41(10): 2878–2883.

作者简介:



李倩玉, 硕士研究生, 主要研究方向为深度学习、生物电信号。



王蓓, 副研究员, 主要研究方向为智能信息处理和模式分类、复杂系统及其在人工生命科学中的应用。主持国家自然科学基金项目、上海市科委科技创新行动计划等 5 项。发表学术论文 50 余篇。



金晶, 教授, 博士生导师, 主要研究方向为脑-机接口、信号处理和模式识别。主持国家级和省部级科研项目 20 余项。发表学术论文 130 余篇。