

基于 CNN-BiLSTM 的自动睡眠分期算法^①



卢伊虹, 吴礼祝, 潘家辉

(华南师范大学 软件学院, 佛山 528225)

通信作者: 潘家辉, E-mail: panjh82@qq.com

摘要: 睡眠分期是睡眠数据分析的基础, 针对目前睡眠分期存在的依赖人工提取、人工判别效率低、自动睡眠分期准确率不高等问题, 本文研究模型是基于卷积神经网络和双向长短时记忆神经网络 2 个深度学习神经网络相结合的, 利用脑电信号来进行自动睡眠分期的模型方法. 算法能提取得到原始脑电信号的梅尔频谱, 利用卷积神经网络和双向长短时记忆神经网络进行时频域的特征提取, 卷积神经网络能够提取睡眠信号高级特征, 双向长短时记忆神经网络结合睡眠数据不同时期的关联性, 提高自动睡眠分期的准确率. 实验结果表明, 本文方法在 Sleep-EDF 数据集的 3 种状态睡眠分期任务中取得 89.0% 的平均准确率. 与传统的基于统计规则的分期模型相比, 本文模型的准确率更高, 且简单高效, 泛化性能更好. 本文算法适用于非线性、不稳定、有幅度起伏变动的脑电信号, 有效提高了自动睡眠分期模型结果的准确率, 对现代睡眠医学、睡眠障碍等分析研究具有一定的实用价值.

关键词: 睡眠分期; 脑电信号; 卷积神经网络; 双向长短时记忆神经网络; 梅尔频谱; 深度学习; 特征提取

引用格式: 卢伊虹, 吴礼祝, 潘家辉. 基于 CNN-BiLSTM 的自动睡眠分期算法. 计算机系统应用, 2022, 31(4): 180-187. <http://www.c-s-a.org.cn/1003-3254/8450.html>

Sleep Staging Classification Based on CNN-BiLSTM

LU Yi-Hong, WU Li-Zhu, PAN Jia-Hui

(School of Software, South China Normal University, Foshan 528225, China)

Abstract: Sleep staging is the basis of sleep data analysis. Given the dependence on manual extraction, the inefficiency of manual classification, and the inaccuracy of automatic sleep staging of current sleep staging methods, this study proposes a method that combines two deep-learning neural networks, namely the convolutional neural network (CNN) and the bidirectional long-short memory neural network (BiLSTM), and uses electroencephalogram (EEG) data to conduct automatic sleep staging. This algorithm can extract mel spectrograms to obtain the original EEG data and use CNN and BiLSTM to extract features in the time domain and the frequency domain. CNN can extract the high-level features of sleep signals, and BiLSTM can improve the accuracy of automatic sleep staging when combined with the correlation of sleep data of different stages. The experimental results show that the proposed method achieves an average accuracy of 89.0% in the three-state sleep staging task on the Sleep-EDF dataset. Compared with the traditional staging model based on statistical rules, this model is simpler, more accurate, and more efficient and has better generalization performance. The proposed algorithm is suitable for nonlinear, unstable, and non-stationary EEG data and effectively improves the accuracy of the results of the automatic sleep staging model. It possesses practical value in modern sleep medicine, sleep disorders, and other research.

Key words: sleep staging; electroencephalogram (EEG); convolutional neural network (CNN); bidirectional long-short memory neural network (BiLSTM); Mel spectrogram; deep learning; feature extraction

① 基金项目: 广东省重点研发计划 (2018B030339001); 国家自然科学基金面上项目 (62076103); 广东省自然科学基金面上项目 (2019A1515011375)

收稿时间: 2021-07-11; 修改时间: 2021-08-04; 采用时间: 2021-08-17; csa 在线出版时间: 2022-03-22

1 引言

1.1 研究背景

睡眠是人类各类生理活动进行过程中不可或缺的重要生理活动, 睡眠时间大约占了人的一生中 33% 的时间. 良好的睡眠是人们健康生活的重要保障, 保证人们进行正常的学习、生活和工作等生产生活方式, 维持人类基本的生理机能活动. 然而在现实生活中, 越来越多的人遭受到睡眠问题, 这极大干扰了人的正常生活. 而睡眠分期作为睡眠医学研究过程中的一个重要步骤, 可以有效监测、检查和评估睡眠质量, 为各类睡眠疾病诊断过程中提供了重要依据, 是诊断睡眠问题的关键前提. 旧时传统的人工判别睡眠分期主要是通过医学专家的视觉分析来完成, 专家需要花费很多时间去判定, 且仅靠专家肉眼观察分析, 效率非常低, 容易造成错误判断^[1]. 利用深度学习和机器学习等技术现代信号处理技术对睡眠生理信号实现自动分期, 分期结果更加高效、客观, 这是当代研究自动化睡眠分期的主要方向趋势, 也为未来睡眠问题分析和研究提供了很多机遇和挑战. 机器学习主要是基于输入的自定义特征、训练出一个合适的分类算法模型, 根据睡眠各个阶段凸出的明显特征来分类实现自动睡眠分期. 其存在一定的局限性. 一是需要专家依靠先验知识手动设计特征. 二是设计的特征不能完全与睡眠阶段贴切相符, 目前还没有找到一个最优的睡眠特征与分类器的组合, 说明距离睡眠分期准确率的提高始终有“天花板”存在. 而深度学习能够从输入的脑电数据中自动进行特征表示, 可以通过睡眠脑电数据测试集中找到最优最合适的睡眠特征, 再结合分类器输出最终的睡眠分期结果. 但是深度学习算法得到的抽象特征往往不能被人们理解和解释, 网络层数越多, 得到的特征越复杂, 同时深度学习对于调参、网络层数设定、最优算法选择等方面需要花费很多时间精力, 对开发人员也有一定的专业知识储备要求. 然而当今社会中深度学习依然是解决很多优化分类问题的绝佳方法, 具有良好的泛化性能.

基于上述考虑, 本文选取 CNN 卷积神经网络与 BiLSTM 相结合, 利用卷积神经网络中提取的高维特征向量按时间作为 BiLSTM 的输入, 训练出一个可以捕捉脑电数据时间依赖性的神经网络模型, 不但可以利用卷积神经网络提取局部特征的优势, 而且能利用双向长短时记忆网络兼顾长时间序列全局特征的优势,

同时进行结构建模获取更高的分类准确率.

1.2 研究现状

(1) 关于睡眠分期的研究

在睡眠分期之前, 首先要确定模型分析结果所要遵守的分期标准. 目前典型的睡眠分期标准有两个, 一个是《人类睡眠阶段标准化术语, 技术及划分系统手册》, 由 Rechtschaffen 和 Kales 提出并制定, 故简称 R&K 标准^[2]. 另一个是由美国睡眠医学会针对 R&K 标准提出的修正版本, 简称 AASM 标准. R&K 标准, 将整个睡眠过程划分为 3 个具有一定明显不同特征的分期阶段, 第 1 个是清醒期 (W), 第 2 个是快速眼动期 (REM), 最后一个是非快速眼动期 (NREM). 非快速眼动期可以继续划分为 4 个时期, 即睡眠 1 期、睡眠 2 期、睡眠 3 期和睡眠 4 期, 一般标记为 S1 期、S2 期、S3 期和 S4 期, 其中, S1 期和 S2 期为浅睡眠期 (light sleep, LS), S2 期和 S3 期为深睡眠期或慢波睡眠期 (slow wave sleep, SWS). AASM 标准, 与 R&K 标准进行比较, 其主要变化的是, 将非快速眼动期分为非快速眼动一期、非快速眼动二期和非快速眼动三期, 一般标记为 N1 期、N2 期和 N3 期, 其中, N1 期和 N2 期为浅睡眠期, N3 期为深睡眠期 (慢波睡眠期).

(2) 基于脑电信号 (electroencephalogram, EEG) 的睡眠分期现状

现阶段, 对于获取到的睡眠脑电信号, 如何从脑电信号中提取到合适的高级特征, 并根据特征将睡眠状态进行分类, 是脑电信号能否在睡眠分期中得到应用的关键性一步. 近年来, 许多研究提出了基于脑电信号的睡眠分期算法, 其中, Phan 等人于 2016 年使用 CNN 神经网络提取原始的脑电信号中的特征, 但是并不是以神经网络端到端的学习形式进行特征的提取^[3]. 随后, 有学者对脑电信号的特征提取进行了神经网络端到端的自动学习, 但睡眠分期的效果并不是很好^[4,5]. 考虑到脑电信号具有时序依赖性和连续性, 研究人员曾使用循环神经网络 (recurrent neural network, RNN) 进行睡眠分期, 实验结果表明 RNN 网络能够有效地提高睡眠分期的准确率. 然而, 该模型对于一些特殊的睡眠时期的分期准确率并不是太高^[6]. Supratak 等人基于原始单通道 EEG 提出了结合卷积神经网络和双向长短时记忆网络的深度学习模型 DeepSleepNet, 用于自动睡眠阶段评分, 总体准确率达到 82.00%^[7]; Mousavi 等人基于单通道 EEG 提出了由深度卷积神经网络组成的 SleepEEGNet, 总体准

准确率达到 84.26%^[8]; Phan 等人提出分层递归神经网络 SeqSleepNet, 将自动睡眠分期作为序列到序列的分类问题来解决, 总体准确率达到 87.10%^[9]. 近年来, 随着 CNN 技术的探索发展, 其被广泛应用于语音识别处理、图像处理、机器视觉、自然语言等领域. 2011 年 Cecotti 等人将 CNN 应用到基于脑电信号的 P300 研究实验中^[10], 而且也有将 CNN 与 LSTM 进行结合应用于时间序列的数据, 例如将 CNN-LSTM 进行电影类型的分类. 融合 CNN 与 BiLSTM 的模型算法还用于心律失常心拍分类中, 其识别准确率相对单独的 CNN 使用与单独的 BiLSTM 使用分别提高了 13.97% 和 7.14%^[11]. 利用 CNN 与 BiLSTM 网络特征结合进行文本情感分析, 也能有效地提高分类的准确率^[12]. 在进行短文本相似度计算中, CNN 与 BiLSTM 相结合的网络结构模型优于其他方法, 其准确率达到 84.58%^[13]. 针对上述研究, 可以发现 CNN 与 BiLSTM 相结合的混合神经网络在分类问题研究中具有明显的优点. 而睡眠数据作为一种具有时序信息的信号, 显然地, 实现睡眠自动分期如果要达到更佳的效果, 我们需要考虑到脑电信号前后数据信息之间的时序依赖性和联系性, 而 CNN-BiLSTM 神经网络可以更好地探究睡眠数据前后序列时间信息的关联和依赖, 所以本文中采用 CNN-BiLSTM 神经网络模型对睡眠脑电数据进行分期研究.

2 基于脑电信号的睡眠分期

2.1 预处理

本文模型使用的睡眠数据是 MIT-BIH 生理信息库中 Sleep-EDF 的多通道脑电信号的真实数据, 数据记录了正常人的睡眠状态数据. 对脑电信号数据的预处理方法步骤如下.

(1) 首先提取公开数据集中两个 EEG 信号 (Fpz-Cz 通道和 Pz-Oz 通道) 与医学专家人工判别的睡眠分期标签, 将其解析存储为 pkl 文件.

(2) 把连续 30 s 的睡眠数据划分为一个睡眠片段, 按照专家的判定将每个睡眠片段划分为 WAKE、NREM 和 REM 期, 根据对应的睡眠分期标签“W, 1, 2, 3, 4, R”转化为“0, 1, 1, 1, 1, 2”, 即分别对应着 3 分类睡眠阶段.

(3) 每次加载 5 个连续 30 s 的睡眠数据和判别标签, 对数据使用 Mel 带通滤波器处理, 可以得出相应的频谱 Mel Spectrogram. 滤波后, 将其中每 5 段连续 30 s 的脑电信号数据归为一个组别, 构造成为特征矩阵.

2.2 CNN 特征学习

卷积神经网络 (CNN) 的核心思想是: 局部感知野、权值共享和下采样 pooling 层, 这 3 种核心思想共同作用, 减少了网络使用的内存量, 简单化网络参数, 提高了精度准确率和网络运算速度, 缓解了过拟合的网络问题^[14]. 从功能结构划分来看, 卷积神经网络可以分为 6 个部分: 信息输入层、卷积运算层、归一化层、ReLU 激活层、池化层和全连接层. 本文模型用到的 CNN 深度神经网络结构如图 1 所示.



图 1 CNN 网络结构图

卷积运算层主要进行两个关键步骤操作: 数据局部关联和窗口滑动. 卷积运算层公式如下:

$$H_i = f_{cov}(H_{i-1} \otimes W_i + b_i) \quad (1)$$

式中, f_{cov} 为激活函数, H_i 代表卷积网络的第 i 层的特征输出, 运算符“ \otimes ”代表卷积运算, b_i 是偏置项, W_i 表示第 i 层使用的卷积核的权重值, 卷积操作的输出与偏置项的结果进行相加, 再将数据通过激活函数进行处理, CNN 网络的卷积操作能够提取输入数据信号的各种不一样的特征^[6]. 在 CNN 网络中的数据输入层将幅度归一化到同样的范围, 其输出数据再作为激活层的输入值, 以调整激活函数的偏导. 目前, ReLU 函数作为比较常用的激活函数, 在本文中我们采用 ReLU 函数:

$$f_{cov}(x) = \max(0, x) \quad (2)$$

这里使用 max 最大值函数对输入值和 0 进行比较取最大值. 激活函数可以加入非线性因素, 解决线性模型不能解决的问题, 同时提高模型鲁棒性和充分组合特征, 将特征图投射到新的一个特征空间, 有利于训练睡眠数据. 激活层后面紧接着的是池化层, 本文网络模型采用最大化池化方法, 池化层主要作用有特征降维、特征不变性和避免过拟合. 全连接层一般出现在池化层的后面, 用于分类, 对提取的特征进行整合处理^[15]. 最后输出层采用 Softmax 函数作为激活函数, 输出 EEG 信号睡眠分期三分类结果.

2.3 LSTM 特征学习

LSTM 长短期记忆神经网络本质上属于一种特殊的 RNN 神经网络. 与传统普通的 RNN 进行比较, LSTM 能够学习长序列信息前后的依赖和关联关系, 记录间隔或延迟较长的历史信息 and 重要事件. 从结构来看, LSTM 的结构中添加了一个细胞神经状态单元, 由门控制去选择性地让信息通过, 添加或者删除信息. LSTM 神经网络具有 3 大特殊功能门, 即遗忘门、输入门和输出门^[16]. LSTM 详细结构架构图如图 2 所示.

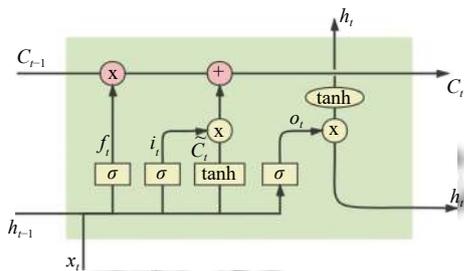


图 2 LSTM 模型结构图

相关计算公式如下:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (3)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (4)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (5)$$

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (6)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (7)$$

$$h_t = o_t \times \tanh(C_t) \quad (8)$$

式中, \tilde{C}_t 为细胞单元暂时性的状态, C_t 为细胞单元状态输出, f_t 为 LSTM 遗忘门信号, i_t 为其输入门信号, o_t 为输出门信号, h_t 为最后的输出信号, W_f, W_i, W_c, W_o 为公式的权重矩阵, b_f, b_i, b_c, b_o 为公式的偏置项.

2.4 建立 CNN-BiLSTM 网络模型

考虑到脑电 EEG 数据是非平稳、非线性数据, 传统的方法进行睡眠自动分期遇到了诸多困难. 目前来说, CNN 适合处理网络结构数据如计算机视觉的图片二维数据. LSTM 深度学习神经网络改善了 RNN 梯度消失和爆炸的问题, 与之相比更适合处理长时序序列前后类型如脑电信号的数据, 尤其在预估和处理长序列数据中间隔或延迟相对时间比较长的事件方面有极大的优势. 但是就目前来看, CNN 和 LSTM 相结合形成的神经网络模型应用于一维生物信号 (如 EEG、

EOG、EMG 等) 的分类相对较少.

本文深度学习神经网络模型主要是由卷积神经网络和双向长短时记忆神经网络两部分组成. CNN 是深度学习神经网络的一个重要部分, 它的权值共享网络结构, 使神经网络模型的复杂度下降, 且图像数据输入到 CNN 网络中, 从而减少复杂的数据提取特征过程和重新建构数据过程, 上一层的局部数据区域通过窗口滑动和权值共享的卷积核运算操作可以得到下一层的特征, 这个特性使得 CNN 比其他神经网络模型对图像特征的提取、研究、表示与分析更加准确和高效. 在本文中, CNN 用来提取脑电数据的特征, 基于 EEG 信号的时频分析可以得出三维特征矩阵, 之后用来构建自动睡眠分期网络模型. 由于人的睡眠数据中包含着大量时间序列数据信息, 而且其在时域上也包含一定的各个不同的睡眠期的隐含特征信息, 本文考虑到每个睡眠周期前后是有关联的和有联系的, 所以采用的模型为卷积神经网络与双向长短时记忆神经网络 (BiLSTM) 的结合. 前向 LSTM 和后向 LSTM 的结合构成了双向长短时记忆网络 BiLSTM, BiLSTM 从两个不同方向处理长序列的睡眠脑电数据信息, 可以更好地挖掘探索双向时序信息和捕捉前后时序数据信息关联和依赖性.

该网络可以自动提取脑电信号 EEG 的长时间序列信息. 该神经网络最后一层是 Softmax 分类器输出层, 用于输出各类睡眠分期结果的概率. 图 3 是本文的 CNN-BiLSTM 网络模型架构概括图.

首先将原始信号经过预处理, 计算每段 30 s 的时间序列 EEG 数据的 Mel 频谱图, 再将两个脑电通道的数据分别按照 5 组连续的 30 s 睡眠片段作为 5 组连续的时间关联数据输入到模型中. 输入层大小为 (64, 47). 模型使用两个二维卷积层 (Conv2d), 第一个卷积层的卷积核个数为 8, 卷积核大小为 (3, 3), 第二个卷积层的卷积核个数为 16, 卷积核大小为 (3, 3); 在两个卷积层之后进行批标准化 (batch normalization); 通过 ReLU 激活函数; 再通过二维最大池化层 (MaxPooling2d), 大小均为 (4, 4); 为了避免训练过程中的过拟合问题^[17], dropout 层 (ratio=0.2) 需要连接到每个池化层后面; 再连接 Flatten 层, 将多维数据转化为一维数据, 实现数据从卷积层过渡到全连接层; 经过标准的 Dense 一维全连接层, 输出维度为 30, 进行归一化和 ReLU 激活函数, 实现从卷积层到长短时记忆神经网络的过渡; 每 5 组

连续的时间关联数据的睡眠信号经过卷积神经网络提取特征后,得到(5, 60)输出维度;模型使用一个双向的长短时记忆时间网络,其中LSTM输出维度unit=15,经过前后向LSTM的结合得到的数据维度为(5, 30);最后将BiLSTM输出的特征经过Softmax层进行三分类任务,将睡眠状态分为WAKE, NREM, REM三个时期。

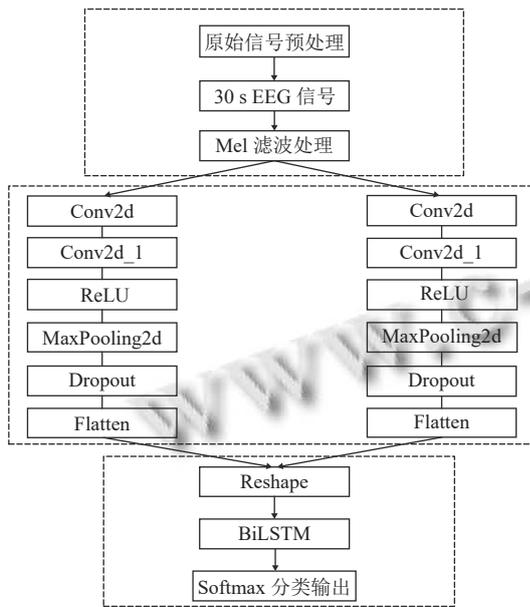


图3 本文模型结构图

我们使用多分类的对数损失函数 (categorical_crossentropy), 该损失函数与 Softmax 分类器相对应; 通过 Adam 优化损失函数, 能够动态地调整每个参数的学习率. 为了避免过拟合现象, 模型在训练过程中使用了早停机制, 若连续迭代 3 次损失率不下降, 则停止训练.

3 实验结果

3.1 实验数据及说明

实验数据为 MIT-BIH 生理信息库 Sleep-EDF 多参数睡眠数据集, 包含 197 个整夜的多导睡眠图 (polysomnographic, PSG) 睡眠记录, 其中包含 EEG, EOG 等生理数据, 每条数据均有明确的人工睡眠分期标签, 该数据集由睡眠盒式磁带对年龄在 25-101 岁的健康白人记录了大约 20 小时的 PSG 和利用射频发射的记录仪对 22 名白人男性和女性服用药物后在医院记录了大约 9 个小时的 PSG 组成.

根据 R&K 标准, 根据睡眠信息数据各阶段的不同特征, 我们可以将睡眠阶段分为 3 期, 即人体睡眠清醒

期、快速眼动期和非快速眼动期. 本实验采用两个通道 (EEG Fpz-Cz 和 EEG Pz-Oz) 的数据组合, 记录频率为 100 Hz, 划分连续 30 s 的睡眠脑电数据作为睡眠样本单元, 最后显示一个总的参考性的睡眠状态.

在本文实验中, 我们选择数据集中 80% 的数据作为数据训练集来训练网络模型, 10% 的数据作为验证集验证模型的能力从而进行模型迭代训练, 10% 的数据作为测试集评估最终模型的泛化能力.

3.2 评价方法

这里采用测试集的睡眠分期结果的准确率 P 来评价各阶段睡眠分期分类结果.

$$P = N_P / N \tag{9}$$

其中, 各睡眠分期 (WAKE, NREM, REM) 都用 N_P 表示预测出正确睡眠分期分类结果的样本数量, N 代表对应睡眠分期阶段在模型实验过程中使用的脑电数据样本数量.

采取子类平均准确AVG评价睡眠分期方法.

$$AVG = \sum_{i=1}^3 P_i / 3 \tag{10}$$

式中, $P_i, i=1, 2, 3$ 分别表示 WAKE, NREM, REM 3 期的子类睡眠分期准确率.

3.3 实验结果与分析

本文采用 Sleep-EDF 数据集的 CNN-BiLSTM 神经网络模型实现自动睡眠分期, 使用 23 个实验对象的脑电数据作为测试集对训练完成的模型进行精度检测, 最终预测结果的混淆矩阵如表 1 所示.

表1 分期混淆矩阵表

类别	WAKE	NREM	REM
WAKE	36463	676	105
NREM	391	14435	817
REM	85	902	3241

混淆矩阵能够很好地检测分类的准确性, 其每一列代表预测的睡眠阶段数, 每一行代表的是实际的睡眠阶段数. 本文睡眠分期为三分类任务, 即得到的混淆矩阵为 3×3 矩阵, 其中, 对角线上的数值代表正确的分类数, 非对角线上的数据代表错误的分类数. 从表 1 可得, 测试集中实际为 WAKE 期睡眠状态的数据共有 37244 个, 模型将其中 676 个数据分类为 NREM 期, 105 个数据分类为 REM 期; 测试集中实际为 NREM 期睡眠状态的数据共有 15643 个, 模型将其中 391 个

数据分类为 WAKE 期, 817 个数据分类为 REM 期; 测试集中实际为 REM 期睡眠状态的数据共有 4 228 个, 模型将其中 85 个数据分类为 WAKE 期, 902 个数据分类为 NREM 期。

从表中的混淆矩阵可以计算得出, 模型在 WAKE 期的准确率 P 可以达到 97.9%, 在 NREM 期 P 可以达到 92.3%, 都具有较高的准确率, 在 REM 期的准确率 P 为 76.7%, 目前还有待提升。图 4 给出了每个睡眠阶段时期的分期准确率数据显示。

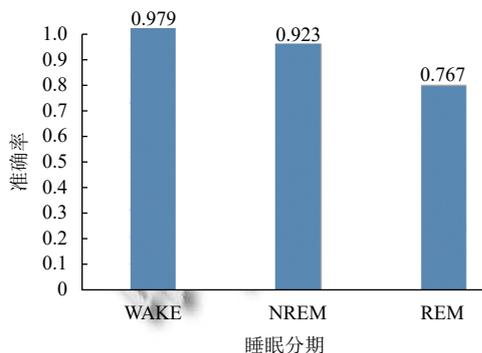


图 4 分期准确率

根据式 (10) 可以求得模型的平均准确率 $ACC=89.0\%$ 。从图 4 中可以看出, 3 个睡眠时期都取得了较高的分期准确率。进一步结合表 1 的分期结果混淆矩阵分析可得, 本文提出的睡眠分期算法能够较精确地识别出 WAKE 期和 NREM 期, 准确率分别达到 97.9% 和 92.3%。除此之外, REM 期的准确率也达到了 76.7% 以上。在对脑电信号进行自动睡眠分期的过程中, 本文所提出的分期算法的总体准确率可以达到 89.0%, 这表明本文提出的算法模型在自动睡眠分期应用中具有良好的分期效果。

目前已经有很多的学者致力于对睡眠脑电 EEG 的自动分期研究, 为了能够更加全面地分析本文模型算法的分期结果, 本文将近年来有代表性的基于 Sleep-EDF 公共数据集的睡眠分期模型与本文的模型进行了对比分析, 如表 2 所示。

表 2 中, Tsinalis 等人^[18,19] 使用机器学习算法 Complex Morlet Wavelets+L-BFGS 对 Fpz-Cz 和 Pz-Oz 两个通道进行五分类睡眠分期, 得到 78.9% 的准确率, 随后, 又使用 CNN 神经网络模型进行单通道睡眠信号五分类分期, 并从公开数据集选取 20 位实验对象的数据进行分析, 最终得到 74.8% 的准确率, 这与本文选取 23 位

实验对象进行准确率评估较为接近; 除此之外, Hassan 等人^[20] 使用 Spectral features+K-W test+AdaBoost.M2 的模型对 Pz-Oz 单个脑电通道进行四分类睡眠分期, 得到 82.8% 的准确率; Andreotti 等人^[21] 使用 ResNet 模型对 Fpz-Cz+EOG 的脑电信号和眼电信号进行五分类睡眠分期, 得到 86.1% 的准确率; Phan 等人^[3] 使用 Image representation + MTCNN 模型对 Fpz-Cz+EOG 的脑电信号和眼电信号进行五分类睡眠分期, 得到 82.3% 的准确率; Chen 等人^[22] 使用 Wavelet+SVM 模型对单个 Fpz-Cz 脑电通道进行四分类睡眠分期, 得到 86.8% 的准确率。对比表 2 中的结果, 单纯从算法的准确率上比较, 本文提出的算法在同一个数据集上的准确率达到了一个较高的水平。

表 2 基于 Sleep-EDF 公共数据集的其它文献比较

工作	输入信号	算法模型	准确率 (%)
文献[18]	Fpz-Cz	CNN	74.8
文献[20]	Pz-Oz	Spectral features + K-W test + AdaBoost.M2	82.8
文献[19]	Fpz-Cz + Pz-Oz	Complex Morlet Wavelets + L-BFGS	78.9
文献[21]	Fpz-Cz + EOG	ResNet	86.1
文献[3]	Fpz-Cz + EOG	Image representation + MTCNN	82.3
文献[22]	Fpz-Cz	Wavelet + SVM	86.8
本文工作	Fpz-Cz +Pz-Oz	CNN + BiLSTM	89.0

可以看出, 本文提出的算法在睡眠分期的准确度上有了进一步的突破。与其它文献中的分期方法相比, 本文模型具有以下不同: ① 本文创新性地采用 Mel 滤波器进行睡眠脑电信号的预处理, 对每一个睡眠周期计算 Mel 频谱图, 通过 Mel 频谱对信号进行时频转换具有不错的效果; ② 本文采用了融合 CNN 和 BiLSTM 的神经网络模型, 充分挖掘了双向时间结构的信息, 实现更精确的特征提取; ③ 本文实现的是三分类算法, 在一定程度上也提高了模型的准确率。

为了更清楚地展示本文所提出的模型对于睡眠时期自动分类的结果, 本文将公开数据集的其中一名实验者数据, 也就是文件名为 SC4001E0-PSG.edf 的专家给定标签以及本文模型预测的结果进行分别绘制了睡眠时相图, 其中横轴为时间, 即持续了 23 小时的睡眠数据, 纵轴为 3 个睡眠期分类。

图 5 中给出了专家对这个持续 23 小时的实验睡

眠数据进行了人工判定,实验被试在不同的时间段分别处于不同的睡眠阶段,根据人工判断结果,在12:35–20:35时间段与03:35之后的时间内,该名被试者一直处于WAKE期,在20:35–03:35时间段内,被试者进入睡眠状态,其睡眠状态随着时间的改变在WAKE、NREM、REM三种睡眠状态下不断进行变化.而图6中则是使用本文提出的模型对该睡眠数据进行分期的结果.从模型进行分期的结果中可以看到,模型对这个持续23小时的睡眠数据都进行了分期,且在12:35–20:35时间段和03:35之后的时间内,模型得到的分期结果也为WAKE期,与图5基本接近;在20:35–03:35时间段内,模型得出的分期结果也在WAKE、NREM、REM三种睡眠状态下进行变化,但与图5还存在一些差异.

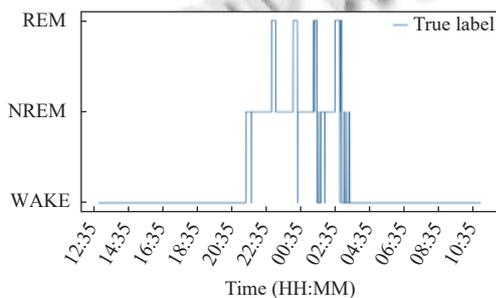


图5 专家分期结果时相图

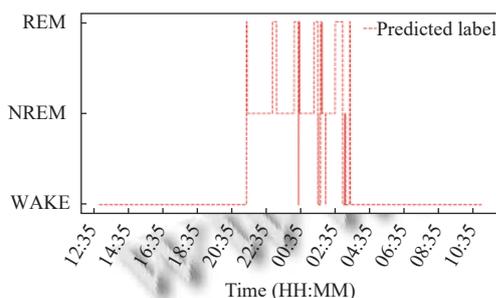


图6 预测结果时相图

通过对比图5和图6,可以看出本文自动睡眠分期模型与专家人工判别结果具有较大的重合性,进一步验证了本文模型的准确性较高.但在不同睡眠时期的过渡阶段,模型判定的结果和专家分期结果有些不同,考虑到处于过渡时期的睡眠可能具有不同时期的特征,所以这一误差具有一定的合理性,同时也为本文进一步研究发展指明了方向.

4 结语

经过实验证明,本文提出的基于算法对睡眠信号具有较好的分期性能.算法选取Sleep-EDF数据集中双通道脑电数据Fpz-Cz和Pz-Oz进行分析,使用Mel频谱对信号睡眠信号进行预处理,结合卷积神经网络和双向长短时记忆神经网络进行时频域特征的提取,目前在睡眠分期领域取得了比较好的性能.实验结果表明,本文模型在公开的睡眠数据集上取得了89.0%的整体准确率,其中WAKE期的准确率达到97.9%,NREM期的准确率达到92.3%,REM期的准确率达到76.7%,证明该模型具有良好的睡眠分期能力.再通过将本文的工作与其他算法进行比较,进一步验证了本文算法的有效性.

同时,在对比其他不需要手动提取特征的模型时,本文需要用到的生理信号更少,只需要两个通道的脑电信号.除此之外,本文模型的网络结构更加简单,训练速度也更快.这对于不稳定、有起伏变化、非线性的脑电信号数据分析处理提供了新的研究思路想法和参考价值.

然而,本文提出的算法还存在一定的缺点,在不同睡眠时期的过渡阶段,算法的判定结果与专家分期结果还存在一定的差异,这表明了该算法的分期准确率还有一定上升的空间,为本文进一步研究与发展指明了方向.

参考文献

- 林少倩. 基于脑电信号的睡眠自动分期研究 [硕士学位论文]. 杭州: 浙江工业大学, 2020: 2.
- Hobson JA. A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects. *Electroencephalography & Clinical Neurophysiology*, 1968, 26(6): 644.
- Phan H, Andreotti F, Cooray N, *et al.* Joint classification and prediction CNN framework for automatic sleep stage classification. *IEEE Transactions on Biomedical Engineering*, 2019, 66(5): 1285–1296. [doi: 10.1109/TBME.2018.2872652]
- Liang SF, Kuo CE, Hu YH, *et al.* Automatic stage scoring of single-channel sleep EEG by using multiscale entropy and autoregressive models. *IEEE Transactions on Instrumentation and Measurement*, 2012, 61(6): 1649–1657. [doi: 10.1109/TIM.2012.2187242]
- Zhang JM, Wu Y. A new method for automatic sleep stage

- classification. *IEEE Transactions on Biomedical Circuits and Systems*, 2017, 11(5): 1097–1110. [doi: [10.1109/TBCAS.2017.2719631](https://doi.org/10.1109/TBCAS.2017.2719631)]
- 6 徐富献. 基于深度学习的单通道睡眠分期研究 [硕士学位论文]. 厦门: 厦门大学, 2019: 16–23.
- 7 Supratak A, Dong H, Wu C, *et al.* DeepSleepNet: A model for automatic sleep stage scoring based on raw single-channel EEG. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2017, 25(11): 1998–2008. [doi: [10.1109/TNSRE.2017.2721116](https://doi.org/10.1109/TNSRE.2017.2721116)]
- 8 Mousavi S, Afghah F, Acharya UR. SleepEEGNet: Automated sleep stage scoring with sequence to sequence deep learning approach. *PLoS One*, 2019, 14(5): e0216456. [doi: [10.1371/journal.pone.0216456](https://doi.org/10.1371/journal.pone.0216456)]
- 9 Phan H, Andreotti F, Cooray N, *et al.* SeqSleepNet: End-to-end hierarchical recurrent neural network for sequence-to-sequence automatic sleep staging. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2019, 27(3): 400–410. [doi: [10.1109/TNSRE.2019.2896659](https://doi.org/10.1109/TNSRE.2019.2896659)]
- 10 Cecotti H, Graser A. Convolutional neural networks for P300 detection with application to brain-computer interfaces. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 33(3): 433–445. [doi: [10.1109/TPAMI.2010.125](https://doi.org/10.1109/TPAMI.2010.125)]
- 11 杨浩, 黄茂林, 蔡志鹏, 等. 融合 CNN 和 BiLSTM 的心律失常心拍分类模型. *中国生物医学工程学报*, 2020, 39(6): 719–726. [doi: [10.3969/j.issn.0258-8021.2020.06.009](https://doi.org/10.3969/j.issn.0258-8021.2020.06.009)]
- 12 李洋, 董红斌. 基于 CNN 和 BiLSTM 网络特征融合的文本情感分析. *计算机应用*, 2018, 38(11): 3075–3080. [doi: [10.11772/j.issn.1001-9081.2018041289](https://doi.org/10.11772/j.issn.1001-9081.2018041289)]
- 13 郭浩, 许伟, 卢凯, 等. 基于 CNN 和 BiLSTM 的短文本相似度计算方法. *信息技术与网络安全*, 2019, 38(6): 61–64, 68.
- 14 罗森林, 郝靖伟, 潘丽敏. 基于 CNN-BiLSTM 的自动睡眠分期方法. *北京理工大学学报*, 2020, 40(7): 746–752.
- 15 Xiao YW, Wu J, Lin ZL, *et al.* A deep learning-based multi-model ensemble method for cancer prediction. *Computer Methods and Programs in Biomedicine*, 2018, 153: 1–9. [doi: [10.1016/j.cmpb.2017.09.005](https://doi.org/10.1016/j.cmpb.2017.09.005)]
- 16 Gers FA, Schmidhuber J, Cummins F. Learning to forget: Continual prediction with LSTM. *Neural Computation*, 2000, 12(10): 2451–2471. [doi: [10.1162/089976600300015015](https://doi.org/10.1162/089976600300015015)]
- 17 程俊华, 曾国辉, 鲁敦科, 等. 基于 Dropout 的改进卷积神经网络模型平均方法. *计算机应用*, 2019, 39(6): 1601–1606. [doi: [10.11772/j.issn.1001-9081.2018122501](https://doi.org/10.11772/j.issn.1001-9081.2018122501)]
- 18 Tsinalis O, Matthews P M, Guo YK, *et al.* Automatic sleep stage scoring with single-channel EEG using convolutional neural networks. arXiv: 1610.01683, 2016.
- 19 Tsinalis O, Matthews PM, Guo YK. Automatic sleep stage scoring using time-frequency analysis and stacked sparse autoencoders. *Annals of Biomedical Engineering*, 2016, 44(5): 1587–1597. [doi: [10.1007/s10439-015-1444-y](https://doi.org/10.1007/s10439-015-1444-y)]
- 20 Hassan AR, Bashar SK, Bhuiyan MIH. Automatic classification of sleep stages from single-channel electroencephalogram. *Proceedings of 2015 Annual IEEE India Conference (INDICON)*. New Delhi: IEEE, 2015. 1–6.
- 21 Andreotti F, Phan H, Cooray N, *et al.* Multichannel sleep stage classification and transfer learning using convolutional neural networks. *Proceedings of the 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. Honolulu: IEEE, 2018. 171–174.
- 22 Chen T, Huang HY, Pan JH, *et al.* An EEG-based brain-computer interface for automatic sleep stage classification. *Proceedings of the 13th IEEE Conference on Industrial Electronics and Applications (ICIEA)*. Wuhan: IEEE, 2018. 1988–1991.