



基于一维卷积神经网络的儿童睡眠分期

许力 吴云肖 肖冰 许志飞 张远

One-dimensional convolutional neural network for children's sleep staging

XU Li, WU Yun-xiao, XIAO Bing, XU Zhi-fei, ZHANG Yuan

引用本文:

许力, 吴云肖, 肖冰, 许志飞, 张远. 基于一维卷积神经网络的儿童睡眠分期[J]. *工程科学学报*, 2021, 43(9): 1253–1260. doi: 10.13374/j.issn2095-9389.2021.01.13.011

XU Li, WU Yun-xiao, XIAO Bing, XU Zhi-fei, ZHANG Yuan. One-dimensional convolutional neural network for children's sleep staging[J]. *Chinese Journal of Engineering*, 2021, 43(9): 1253–1260. doi: 10.13374/j.issn2095-9389.2021.01.13.011

在线阅读 View online: <https://doi.org/10.13374/j.issn2095-9389.2021.01.13.011>

您可能感兴趣的其他文章

Articles you may be interested in

基于卷积神经网络的反无人机系统声音识别方法

Sound recognition method of an anti-UAV system based on a convolutional neural network

工程科学学报. 2020, 42(11): 1516 <https://doi.org/10.13374/j.issn2095-9389.2020.06.30.008>

一维卷积神经网络特征提取下微震能级时序预测

Time series prediction of microseismic energy level based on feature extraction of one-dimensional convolutional neural network

工程科学学报. 2021, 43(7): 1003 <https://doi.org/10.13374/j.issn2095-9389.2020.11.22.001>

卷积神经网络在矿区预测中的应用

Research and application of convolutional neural network in mining area prediction

工程科学学报. 2020, 42(12): 1597 <https://doi.org/10.13374/j.issn2095-9389.2020.01.02.001>

基于深度卷积神经网络的地磁导航方向适配性分析

Direction-matching-suitability analysis for geomagnetic navigation based on convolutional neural networks

工程科学学报. 2017, 39(10): 1584 <https://doi.org/10.13374/j.issn2095-9389.2017.10.018>

基于集成神经网络的剩余寿命预测

Remaining useful life prediction based on an integrated neural network

工程科学学报. 2020, 42(10): 1372 <https://doi.org/10.13374/j.issn2095-9389.2019.10.10.005>

基于深度循环神经网络的协作机器人动力学误差补偿

Error compensation of collaborative robot dynamics based on deep recurrent neural network

工程科学学报. 2021, 43(7): 995 <https://doi.org/10.13374/j.issn2095-9389.2020.04.30.003>

基于一维卷积神经网络的儿童睡眠分期

许力¹⁾, 吴云肖²⁾, 肖冰³⁾, 许志飞⁴⁾, 张远¹⁾✉

1) 西南大学电子信息工程学院, 重庆 400715 2) 国家儿童医学中心, 首都医科大学附属北京儿童医院, 儿童耳鼻咽喉头颈外科疾病北京市重点实验室, 北京 100045 3) 民航总医院呼吸内科, 北京 100123 4) 国家儿童医学中心, 首都医科大学附属北京儿童医院呼吸科, 北京 100045

✉通信作者, E-mail: yuanzhang@swu.edu.cn

摘要 高质量睡眠与儿童的身体发育、认知功能、学习和注意力密切相关, 由于儿童睡眠障碍的早期症状不明显, 需要进行长期监测, 因此急需找到一种适用于儿童睡眠监测, 且能够提前预防和诊断此类疾病的方法. 多导睡眠图 (Polysomnography, PSG) 是临床指南推荐的睡眠障碍基本检测方法, 通过观察 PSG 各睡眠期间的变化和规律, 对睡眠质量评估和睡眠障碍识别具有基础作用. 本文对儿童睡眠分期进行了研究, 利用多导睡眠图记录的单通道脑电信号, 在 Alexnet 的基础上, 用一维卷积代替二维卷积, 提出一种 1D-CNN 结构, 由 5 个卷积层、3 个池化层和 3 个全连接层组成, 并在 1D-CNN 中添加了批量归一化层 (Batch normalization layer), 保持卷积核的大小保持不变. 针对数据集少的情况, 采用了重叠的方法对数据集进行了扩充. 实验结果表明, 该模型儿童睡眠分期的准确率为 84.3%. 通过北京市儿童医院的 PSG 数据获得的归一化混淆矩阵, 可以看出, Wake、N2、N3 和 REM 期睡眠的分类性能很好. 对于 N1 期睡眠, 存在将 N1 期睡眠被误分类为 Wake、N2 和 REM 期睡眠的情况, 因此以后的工作应重点提升 N1 期睡眠的准确性. 总体而言, 对于基于带有睡眠阶段标记的单通道 EEG 的自动睡眠分期, 本文提出的 1D-CNN 模型可以实现针对于儿童的自动睡眠分期. 在未来的工作中, 仍需要研究开发更适合于儿童的睡眠分期策略, 在更大数据量的基础上进行实验.

关键词 儿童睡眠分期; 多导睡眠图; 卷积神经网络; Alexnet; 脑电信号

分类号 TG391.7

One-dimensional convolutional neural network for children's sleep staging

XU Li¹⁾, WU Yun-xiao²⁾, XIAO Bing³⁾, XU Zhi-fei⁴⁾, ZHANG Yuan¹⁾✉

1) College of Electronic and Information Engineering, Southwest University, Chongqing 400715, China

2) Beijing Key Laboratory of Pediatric Diseases of Otolaryngology, Head and Neck Surgery, Beijing Children's Hospital, Capital Medical University, National Center for Children's Health, Beijing 100045, China

3) Department of Respiratory Medicine, Civil Aviation General Hospital, Beijing 100123, China

4) Department of Respiratory Medicine, Beijing Children's Hospital, Capital Medical University, National Center for Children's Health, Beijing 100045, China

✉ Corresponding author, E-mail: yuanzhang@swu.edu.cn

ABSTRACT High-quality sleep is linked with physical development, cognitive function, learning, and attention in children. Since early symptoms of sleep disorders in children are not obvious and require long-term monitoring, there is an urgent need to develop a method for monitoring children's sleep that can prevent and diagnose these disorders in advance. Polysomnography (PSG) is the basic test for sleep disorders recommended by clinical guidelines. Sleep quality can be assessed and sleep disorders can be identified by observing the changes in patterns of PSG during each sleep period. Sleep staging in children was researched and single-channel

收稿日期: 2021-01-13

基金项目: 北京市自然科学基金资助项目(7212033); 首都卫生发展科研专项资助项目(首发 2018-4-6031)

electroencephalogram (EEG) signals recorded by PSG was used in this study. On the basis of Alexnet, we use a one-dimensional convolutional neural network (1D-CNN) model instead of a two-dimensional model to propose a 1D-CNN structure composed of five convolutional layers, three pooling layers, and three fully connected layers, as well as a batch normalization layer to 1D-CNN while keeping the size of the convolutional kernel constant. Moreover, the dataset was augmented with an overlapping method to address its small size. The experimental results showed that the accuracy of this model for children's sleep staging was 84.3%. According to the normalized confusion matrix obtained from the PSG data of Beijing Children's Hospital, the classification performance of wake, N2, N3, and REM stages of sleep was very good. Because stage N1 sleep was misclassified as wake, N2, and REM sleep in some cases, future research should focus on improving the accuracy of stage N1 sleep. Overall, the 1D-CNN model proposed in this paper can realize automatic sleep staging for children based on single-channel EEG with sleep stage markers. In the future, more research is needed to develop a more suitable sleep staging strategy for children and to conduct experiments with a larger amount of data.

KEY WORDS children's sleep staging; polysomnography (PSG); convolutional neural network (CNN); Alexnet; electroencephalograph (EEG)

对于儿童来说, 高质量睡眠有助于儿童的智力发育, 与儿童的认知功能、学习和注意力密切相关^[1]. 儿童若不能够获得足够而良好的睡眠, 会影响智力发育, 造成情绪、行为、注意力等方面的问题^[2]. 儿童睡眠障碍一般发生在 2~12 岁的儿童身上, 儿童睡眠障碍表现为在睡眠过程中出现的各种影响睡眠的异常表现^[3]. 它可以由身体某系统的功能失调引起, 也可由疾病引起, 能直接影响儿童的睡眠结构、睡眠质量及睡眠后复原程度^[4].

睡眠相关类疾病早期症状不明显, 容易被忽视, 因此有效的监测对于提前预防和早期诊断睡眠相关类疾病是关键. 睡眠分期是判定睡眠障碍的首要步骤^[5], 通过观察个体睡眠期间脑电信号的变化和规律, 研究发现健康人的睡眠可以依据变化规律分为不同的状态, 这就是睡眠分期. 临床医生通过对患者进行多导睡眠图 (Polysomnography, PSG) 监测来确定睡眠分期^[6]. PSG 一般包括脑电 (Electroencephalograph, EEG)、眼电 (Electrooculogram, EOG)、肌电 (Electromyography, EMG)、心电图 (Electrocardiograph, ECG)、胸式和腹式呼吸运动图、鼻及口气流、体动、血氧饱和度等 10 余个通道的生理信号, 将其经过预处理及分析后, 得出有关睡眠结构、呼吸事件、血氧饱和度、鼾声、体位和心电图动态变化等具体生理参数.

为标准化睡眠分期结果, 1968 年, Rechtschaffen^[7] 等提出了睡眠分期准则 (Rechtschaffen and Kales rule), 又称 R&K 准则. R&K 准则根据 2 路脑电、2 路眼电和 1 路肌电信号将睡眠分为 7 个阶段, 分别为觉醒期 (Wake)、睡眠 I 期 (Stage 1, S1)、II 期 (Stage 2, S2)、III 期 (Stage 3, S3)、IV 期 (Stage 4, S4)、快速眼动期 (REM) 和体动期 (Movement time, MT)^[8]. 2007 年, 美国睡眠医学学

会 (American Academy of Sleep Medicine, AASM) 在 R&K 准则的基础上对睡眠分期标准进行了调整, 提出了 AASM 准则^[9]. 目前 AASM 准则已更新至 2020 版. AASM 准则将 R&K 准则中的 S3 和 S4 期合并为慢波睡眠期 (NREM III 期), 将睡眠阶段重新定义为觉醒期 (Wake, W 期)、非快速眼动期 (NREM, N 期) 和快速眼动期 (REM, R 期). 其中 NREM 被划分为 NREM I 期 (N1)、NREM II 期 (N2) 和 NREM III 期 (N3).

对于睡眠的研究离不开脑电信号 (Electroencephalograph, EEG) 分析. 脑电信号频率分为四个主要频带^[10]: δ (1~3 Hz)、 θ (4~7 Hz)、 α (8~13 Hz)、 β (14~30 Hz). 除这四种主要频带以外, 人们在觉醒并专注于某一事时, 会被检测出一种较 β 波的频率更高的 γ 波 (30~80 Hz). 同时, 人们在睡眠时还可能出现其他一些波形较为特殊的脑电波, 如: σ 波、 λ 波、K 复合波、 μ 波等. 脑电信号在不同时刻会表现出不同的频率分量, 波形的变化会受测试者自身状态影响, 因此极度不稳定并且随机.

美国睡眠研究会睡眠及其相关事件判读手册^[11] 中对儿童睡眠分期判读规则为: 如果全部 NREM 睡眠记录帧没有可识别的睡眠梭形波、K 复合波或 0.5~2.0 Hz 的高振幅慢波活动, 判读所有记录帧为 N 期 (NREM); 如果某些 NREM 睡眠记录帧含有睡眠梭形波或 K 复合波, 这些帧判读为 N2 期 (NREM 2). 剩余的 NREM 睡眠记录帧, 如果慢波活动小于记录帧的 20%, 判读为 N 期; 如果 NREM 睡眠记录帧慢波活动大于 20%, 判读为 N3 期 (NREM 3). 剩余的记录帧, 如果不存在 K 复合波或睡眠梭形波, 判读为 N 期 (NREM). 成人 PSG 设备的 EEG、EOG 和颞 EMG 电极的放

置适用于儿童,但由于儿童头型较小,所以颞EMG电极间距离通常需从2 cm减小到1 cm,EOG电极距眼睛的距离通常需从1 cm减小到0.5 cm.

由于PSG需要专门的睡眠监测室及专业技术人员分析结果,且费用比较昂贵,技术要求高,在临床儿童患者中实施存在一定难度,对疑似的儿童患者无法大规模筛查,且患儿依从性不高、配合度差.而使用单通道EEG可以降低睡眠监测的难度,为便携式可穿戴设备的开发提供基础.

目前已有的自动睡眠分期方法大多是利用单通道或多通道脑电信号,针对成年人的自动睡眠分期规则,而适用于儿童的自动睡眠分期方法很少.由于儿童与成人的EEG存在差异,如儿童的后部优势节律(Posterior dominant rhythm, PDR)在不同年龄稍有不同,儿童N1期会有睡前超同步(HH)和弥散或枕部优势高波幅节律性3~5 Hz活动,这个是成人没有的,所以很多利用机器学习等方法用于成人的自动睡眠分期方法不适用于儿童,因此需要对已有方法进行改进或提出更适用于儿童脑电特征的自动睡眠分期方法.

本文针对睡眠分期这一问题,提出了一种基于单通道脑电信号的端到端一维CNN(1D-CNN)模型,从而克服了手工提取特征受到先验知识的限制;数据集包含14位3到10岁健康受试者,从而保证了模型对儿童睡眠分期的有效性.

1 儿童和成人睡眠分期的相关工作

目前,睡眠分期依然是由睡眠分析技师采用AASM准则对多导睡眠图进行人工分期,但是由于多导睡眠图的数据量非常大,同时由于技师本身的主观因素限制,所以这是一项既耗费时间又难以保持客观性的睡眠分期行为.随着近几年人工智能的发展,越来越多的自动化技术被应用到了医学影像和医学信号领域.

Dong等^[12]提出了一种实用的方法来解决使用单通道脑电图(EEG)进行睡眠阶段分类的局限性.作者利用整流神经网络检测分层特征,利用长短时记忆(LSTM)网络进行序列数据学习,优化单通道记录的分类性能.在探索了替代电极放置后,作者发现了一个舒适的放置于前额的单通道脑电电极位置,并表明它可以与其他电极集成,同时记录眼电图(EOG).通过对62人(494 h睡眠)的数据进行评估,证明该分析算法比现有的顶点或枕部电极放置方法的性能更好.

Supratak等^[13]提出了DeepSleepNet模型,该模

型利用卷积神经网络提取时间不变特征,并利用双向长短期记忆自动学习脑电图分期期间的睡眠转换规律.作者采用了两步训练算法来训练模型,使用来自两个公共睡眠数据集的不同单通道EEGs(F4-EOG(左)、Fpz-Cz和Pz-Oz)评估该模型,结果表明,与最先进的方法相比,该模型在两个数据集上取得了相似的总体精度和f1 score.这表明,在不改变模型架构和训练算法的情况下,该模型可以自动从不同数据集的原始单通道脑电图中学习睡眠阶段评分的特征,实现自动睡眠分期.与之类似,针对帧和序列进行设计的模型还有SeqSleepNet^[14]、SleepEEGNet^[15]、CCRRSleepNet^[16],它们共同关注了睡眠分期的独立性与连续性.

Dehkordi等^[17]分析了从脉搏血氧仪光体积描记图(PPG)中提取的心率变异性的标准特征,以识别不同的睡眠阶段.作者使用多导睡眠图和Phone Oximeter™记录了146名儿童的整晚的PPG信号.根据多导睡眠图,将记录分为1 min,并标记为Wake, non-REM和REM.对于每个时段,估计了心率变异性的六个标准时域和频域特征.作者分别训练了两个支持向量机分类器,以对从睡眠时期中W期和NREM期进行分类.觉醒和睡眠的分类精度为77%,REM和NREM的分类精度为80%.

基于家庭的儿童睡眠监测是一个急需解决的问题.由于EEG是了解睡眠的重要标准,所以监测单通道EEG信号是识别睡眠障碍最有前途的方法.该方法不需要在用户身上附加大量的传感器,更适合儿童的睡眠监测,使得数据更能反应睡眠习惯.目前的研究大多从脑电中提取各种特征作为神经网络的训练样本,将深度学习模型作为进一步特征融合和筛选的工具,没有充分展现深度学习的优势.因此,为了适应当前需求,本文提出了一种基于单通道脑电的儿童睡眠分期算法.

2 研究方法

卷积神经网络(Convolutional neural networks, CNN)是一种深度神经网络.深度学习已在诸如视觉识别,语音识别和自然语言处理等各种问题上取得了很好的成绩.在不同类型的深度神经网络中,关于卷积神经网络的研究最为广泛^[18].图1显示了CNN的层次结构及应用.

2.1 数据扩容

对于儿童睡眠数据少的情况,可采用重叠的方法对数据集进行扩充,规则如下:如果受试者的两个连续时期具有相同的睡眠阶段,则使用滑动

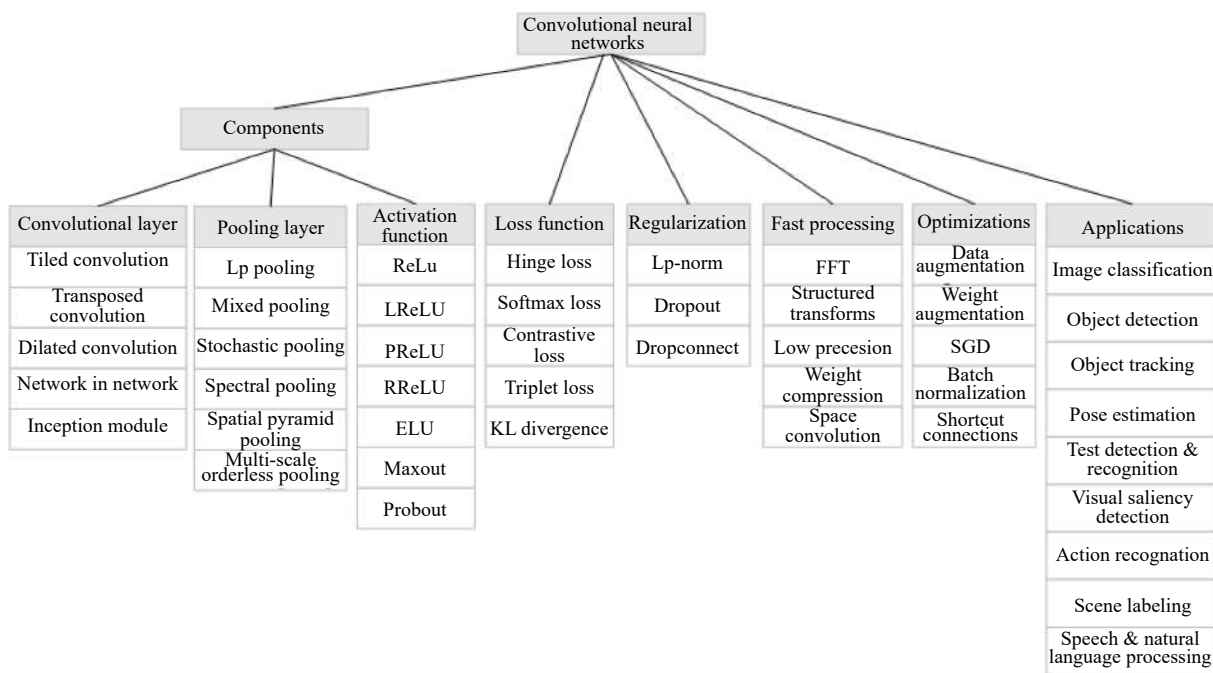


图 1 CNN 的层次结构及应用
Fig.1 CNN architecture and applications

窗口进行重叠, 将重叠时间设置为 25 s, 重叠后新帧(Epoch)的睡眠阶段标签未更改, 如图 2 所示.

相反, 如果两个连续的 epoch 是不同的睡眠阶段, 则不会进行重叠.

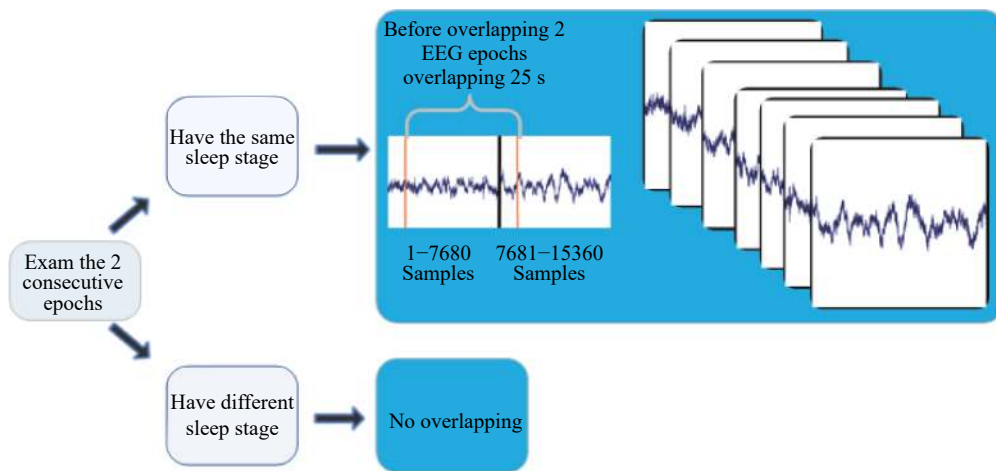


图 2 数据集重叠

Fig.2 Datasets overlapping

由于 EEG 是低频信号, 其频率主要集中在 0.5 ~ 40 Hz^[19], 因此使用了二阶巴特沃斯滤波对原始 EEG 数据进行了预处理, 消除高频噪声和直流成分. 因为儿童慢波活动通常为高波幅(100 ~ 400 μV), 所以不对脑电数据的振幅进行限制.

需要注意的是, 由于 5 个睡眠分期的 epoch 数量不相同且分布不相同, 所以数据集会失去平衡性, 进而影响机器学习算法的性能. 因此, 本研究采用了以下策略来调整每个睡眠分期的 epoch 数量:

(1) 统计数据集中每个睡眠分期的 epoch 数量, 以其中最小数量的类型的 epoch 数量作为阈

值, 每种类型的 epoch 只保留阈值数, 其余的 epoch 被丢弃.

(2) 将平衡后的数据集按 W、N1、N2、N3、R 的顺序重新排列.

2.2 1D-CNN 模型与算法

本研究将 Alexnet^[20] 进行改进, 利用单通道脑电信号(C4-M1 通道), 将 1D 卷积核替换了 2D 卷积核, 并在 1D-CNN 中添加了批量归一化层(Batch normalization layer), 而卷积核的大小保持不变. 1D-CNN 模型的示意图如图 3 所示, 该模型由 5 个卷积层, 3 个池化层和 3 个完全连接的层组成.

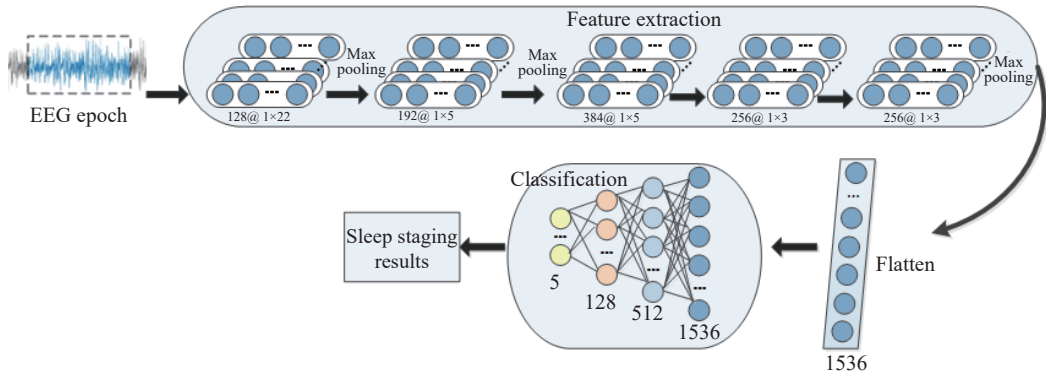


图3 1D-CNN 模型

Fig.3 1D-CNN model

由于 1D-CNN 的输入是 30 s 为一个 epoch 的数据, 即 1×3840 一维时间序列, 因此在模型中使用了 1D 卷积核. 一维卷积运算过程定义为:

$$y_i^l = f\left(\sum_{n=1}^d \omega_n^l \cdot y_{n+i}^{l-1} + b^l\right), i = 1, 2, \dots, N-d+1 \quad (1)$$

式中, y_i^l 是第 l 层上输出要素的第 i 个像素, ω_n^l 和 b^l 分别表示第 l 层的卷积核的权重向量和偏倚参数, d 表示卷积核的大小, N 表示输入特征向量 y_i^{l-1} 的长度, $f(\cdot)$ 表示卷积层的激活函数.

第一和第二卷积层分别使用大小为 1×22 和 1×5 的大卷积核, 而第三到第五卷积层使用大小为 1×3 的小卷积核. 在第一, 第二和第五卷积层之后, 本研究利用大小为 1×3 的 maxpooling 层来减少特征图的尺寸. 将最后一个最大池化层的生成的特征图展平为一维向量. 该向量被送到全连接层以进行二进制分类, 并获得最终的识别结果. 本研究选择 ReLU(整流线性单位)作为激活函数, 其定义如下:

$$f = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (2)$$

批处理归一化层位于第一卷积层之后, 该层可以归一化特征激活, 从而减少内部协变量偏移. 批处理规范化定义如下:

$$\bar{x} = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \lambda}} \quad (3)$$

$$y_i = \gamma \bar{x}_i + \beta \quad (4)$$

式中, B 代表包含 m 个样本的小批量, μ_B 和 σ_B^2 分别代表 B 的均值和方差. λ 是数值稳定性的常数, γ 和 β 分别是训练过程中计算出的比例和移位参数, 有关详细信息, 请参见文献 [21].

2.3 睡眠分期系统

针对现实需求, 以 PyQt 为基础, 设计开发了睡

眠分期系统, 方便医生的使用, 如图 4 所示, 该图展示了一段时长为 60 s 的多导睡眠图, 图中展示了前 8 个通道的生物电信号, 即 2 个眼电通道与 6 个脑电通道, 并用颜色区分了不同的睡眠分期, 可以看到, 该 60 s 由一个 N2 期的后半部分、一个完整的 W 期和一个 N1 期的开始部分组成.

3 实验过程

3.1 数据集

本研究中使用的数据集来自首都医科大学附属北京儿童医院, 数据集包括来自 14 位受试者的 PSG 记录. 每位受试者至少记录 6 条 EEG 通道, 2 条 EOG 通道. 原始数据集 epoch 数量为 14383, 重叠、平衡后的 epoch 数量为 30195.

3.2 实验环境

数据预处理和功能提取部分是在 PyCharm 2020.1.2 环境中在具有 64 GB RAM 的 AMD Ryzen7-3700x@3.60 GHz 上实现的. 深度学习实验是在 NVIDIA GeForce RTX 2080 Ti 上利用 tensorflow 框架在 Python 环境中进行的.

3.3 实验参数

数据预处理利用 kaiming 初始化器^[22]初始化 1D-CNN 中的权重参数, 这可以提高模型的收敛速度. 使用 Adam 优化器^[23]以 0.00001 学习率进行参数优化. 批处理大小为 256 个. 在此研究中使用了交叉熵损失函数, 其定义为:

$$E_n = -\frac{1}{N} \sum_{k=1}^N p_k \cdot \ln(y_k) + (1 - p_k) \ln(1 - y_k) \quad (5)$$

式中, E_n 是基本的交叉熵损失函数, N 是训练样本的数量, y_k 和 p_k 分别表示样本的真实标签和预测标签.

为了防止过度拟合问题, 本研究使用了 dropout 和 L2 正则化方法. Dropout 可以在训练过程中以

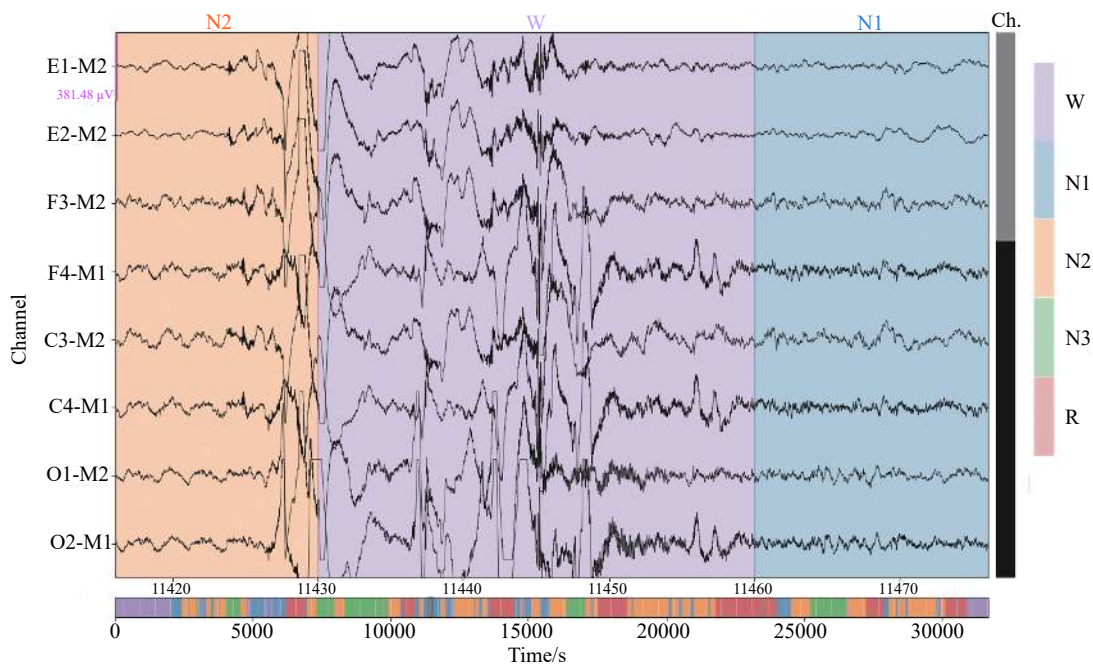


图 4 睡眠分析系统原型

Fig.4 Prototype of the sleep analysis system

指定的概率随机断开层的各个单元^[24]. L2 正则化是在损失函数之后添加正则项以降低网络复杂性. 具有 L2 正则化项的交叉熵损失函数定义为:

$$E_{t_2} = E_n + \lambda \|\omega\|_2^2 \quad (6)$$

式中, $\lambda \|\omega\|_2^2$ 是 L2 正则化项, λ 和 ω 分别是惩罚因子和网络参数. 在本研究中, λ 设置为 0.001. 本研究在全连接层的第一层和第二层之后使用了 0.8 的 dropout. 1D-CNN 的超参数如表 1 所示.

表 1 超参数表

Table 1 Model hyperparameters

Parameter	Value
Optimizer	Adam
Learning rate	0.00001
Loss function	Cross-entropy
Batch size	256
L2 regularization	0.001

在这项研究中, 准确率、精确度、召回率、F1 得分和 Kappa 系数 (K) 用于评估性能.

3.4 实验结果

本研究是在成人自动睡眠分期的研究基础上, 通过改进将 1D-CNN 结构用于儿童自动睡眠分期, 训练集包括从 14 位健康受试者中分出的 30195 个 epoch, 使用了 14 折交叉验证实验, 在每一折中, 利用 1 位受试者的数据作为测试集, 剩下

的 13 位受试者作为训练集, 这个实验需要重复 14 次以保证所有的数据都被使用到. 本研究的准确率为 85.57%. 表 2 各项评价指标的结果. 在训练和预测的速度上, 本研究所用时间均远小于 DeepSleepNet, 约为其 1/5.

表 2 实验结果

Table 2 Experimental results

Method	Accuracy / %	Precision	Recall	F1-score	K
Our method	85.57	0.847	0.866	0.855	0.820
DeepSleepNet	69.58	0.687	0.659	0.632	0.581

由于训练时用到了防止过拟合的 L2 正则化和 dropout, 而验证的时候没有用到正则化和 dropout, 为了防止出现过拟合, 将参数设置的较大, 因此出现验证准确率大于训练准确率的情况. 准确率和损失如图 5 和 6 所示. 图 7 显示了 1D-CNN 模型通过本实验数据获得的归一化混淆矩阵, 其中数字代表分类正确或错误的样本. 通过混淆矩阵可以看出, Wake、N2、N3 和 REM 期睡眠的分类性能很好. 对于 N1 期睡眠, 存在将 N1 期睡眠误分类为 Wake、N2 和 REM 期睡眠的情况, 因此以后的工作应重点研究 N1 期睡眠的准确性.

4 结论

本研究对 Alexnet 进行改进, 提出了一种基于

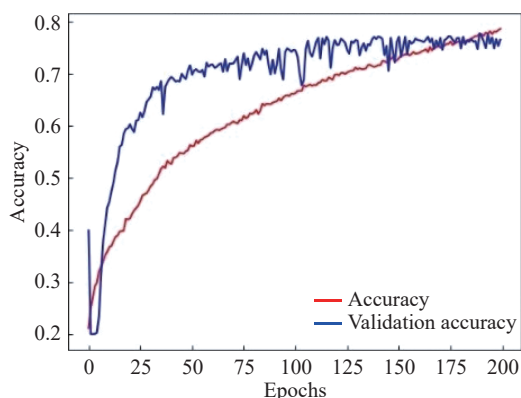


图5 训练和验证准确率

Fig.5 Training and validation accuracy

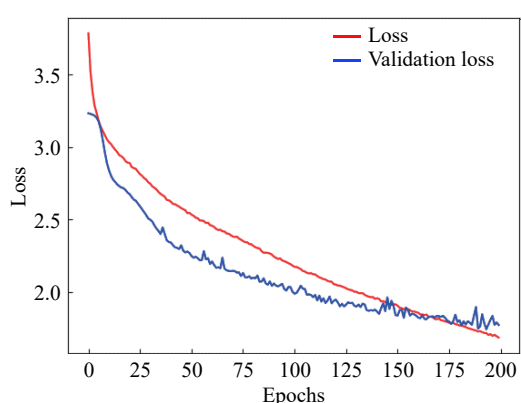


图6 训练和验证损失

Fig.6 Training and validation loss

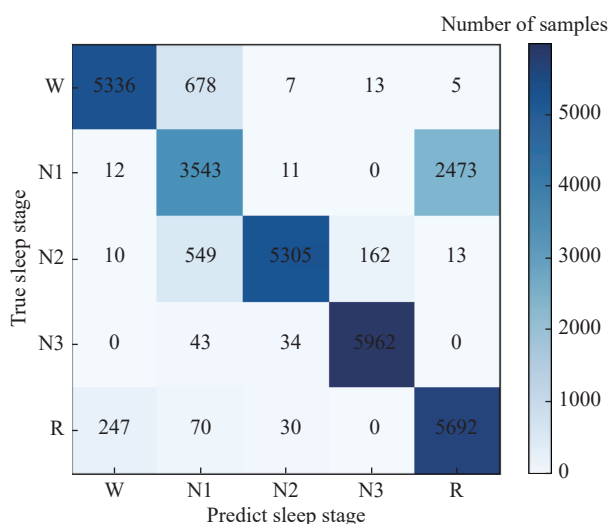


图7 混淆矩阵

Fig.7 Confusion matrix

有标签单通道脑电图的睡眠分期 1D-CNN 模型。由于 1D-CNN 是一个端到端的学习模型, 即将特征提取器和分类器集成到一个算法中。端到端学习方法可以克服手动特征提取的局限性, 从而提高睡眠分期准确率。该模型用于儿童睡眠分期, 对未来利用机器学习方法辅助临床儿童睡眠分期,

设计了研究方案, 为进一步研究儿童睡眠障碍奠定了基础。总体而言, 对于基于带有睡眠阶段标记的单通道 EEG 的自动睡眠分期, 本文介绍的 1D-CNN 模型可以实现针对于儿童的自动睡眠分期。在未来的工作中, 仍需要研究更适合于儿童的睡眠分期策略, 在基于更大数据量的基础上, 进行进一步的实验。在大样本数据集下, 研究可以选择更多的睡眠相关特征进行测试, 并进一步增加一维神经网络的规模, 最大程度地发挥深度卷积神经网络的能力。

参 考 文 献

- [1] Halbower A C, Degaonkar M, Barker P B, et al. Childhood obstructive sleep apnea associates with neuropsychological deficits and neuronal brain injury. *PLoS Med*, 2006, 3(8): e301
- [2] Matricciani L, Paquet C, Galland B, et al. Children's sleep and health: A meta-review. *Sleep Med Rev*, 2019, 46: 136
- [3] Cardoso T S G, Pompéia S, Miranda M C. Cognitive and behavioral effects of obstructive sleep apnea syndrome in children: A systematic literature review. *Sleep Med*, 2018, 46: 46
- [4] Marcus C L, Moore R H, Rosen C L, et al. A randomized trial of adenotonsillectomy for childhood sleep apnea. *N Engl J Med*, 2013, 368(25): 2366
- [5] Tabone L, Khirani S, Amaddeo A, et al. Cerebral oxygenation in children with sleep-disordered breathing. *Paediatr Respir Rev*, 2020, 34: 18
- [6] Rundo J V, Downey III R. Polysomnography. *Handb Clin Neurol*, 2019, 160: 381
- [7] Rechtschaffen A, Kales A. *A Manual of Standardized Terminology, Techniques and Scoring System for Sleep Stages of Human Subjects*. Washington, DC: U.S. Government Printing Office, 1968
- [8] Li Y J, Hong F, Yan H, et al. Research progress in sleep quality evaluation on-orbit. *Space Med Med Eng*, 2012, 25(6): 458 (李延军, 宏峰, 严洪, 等. 在轨睡眠质量评价的研究进展. *航天医学与医学工程*, 2012, 25(6): 458)
- [9] Singh J, Badr M S, Diebert W, et al. American academy of sleep medicine (AASM) position paper for the use of telemedicine for the diagnosis and treatment of sleep disorders. *J Clin Sleep Med*, 2015, 11(10): 1187
- [10] Newson J J, Thiagarajan T C. EEG frequency bands in psychiatric disorders: A review of resting state studies. *Front Hum Neurosci*, 2018, 12: 521
- [11] Berry RB, Albertario CL, Harding SM, et al. *The AASM Manual for the Scoring of Sleep and Associated Events: Rules, Terminology and Technical Specifications (Version 2.5)*. USA: American Academy of Sleep Medicine, 2018
- [12] Dong H, Supratak A, Pan W, et al. Mixed neural network approach for temporal sleep stage classification. *IEEE Trans Neural Syst*

- Rehabilitation Eng*, 2018, 26(2): 324
- [13] Supratak A, Dong H, Wu C, et al. DeepSleepNet: A model for automatic sleep stage scoring based on raw single-channel EEG. *IEEE Trans Neural Syst Rehabilitation Eng*, 2017, 25(11): 1998
- [14] Phan H, Andreotti F, Cooray N, et al. SeqSleepNet: end-to-end hierarchical recurrent neural network for sequence-to-sequence automatic sleep staging. *IEEE Trans Neural Syst Rehabilitation Eng*, 2019, 27(3): 400
- [15] Mousavi S, Afghah F, Acharya U R. SleepEEGNet: Automated sleep stage scoring with sequence to sequence deep learning approach. *PLoS One*, 2019, 14(5): e0216456
- [16] Neng W P, Lu J, Xu L. CCRRSleepNet: A hybrid relational inductive biases network for automatic sleep stage classification on raw single-channel EEG. *Brain Sci*, 2021, 11(4): 456
- [17] Dehkordi P, Garde A, Karlen W, et al. Sleep stage classification in children using photoplethysmogram pulse rate variability // *Computing in Cardiology* 2014. Cambridge, 2014: 297
- [18] Gu J X, Wang Z H, Kuen J, et al. Recent advances in convolutional neural networks. *Pattern Recognit*, 2018, 77: 354
- [19] Feyissa AM, Tatum WO. Adult EEG. *Handb Clin Neurol*, 2019, 160: 103
- [20] Krizhevsky A, Sutskever I, Hinton G. ImageNet classification with deep convolutional neural networks // *NIPS'12: Proceedings of the 25th International Conference on Neural Information Processing Systems*. New York, 2012: 1097
- [21] Kalayeh M M, Shah M. Training faster by separating modes of variation in batch-normalized models. *IEEE Trans Pattern Anal Mach Intell*, 2020, 42(6): 1483
- [22] He K M, Zhang X Y, Ren S Q, et al. Delving deep into rectifiers: Surpassing human-level performance on ImageNet classification // *2015 IEEE International Conference on Computer Vision (ICCV)*. Santiago, 2015: 1026
- [23] Kingma D P, Ba J. Adam: A method for stochastic optimization // *International Conference on Learning Representations*. San Diego, 2015: 13
- [24] Srivastava N, Hinton G, Krizhevsky A, et al. Dropout: A simple way to prevent neural networks from overfitting. *J Mach Learn Res*, 2014, 15: 1929