

DOI: 10.19650/j.cnki.cjsi.J2108202

基于残差收缩网络的睡眠脑电分期*

陈玲玲¹, 毕晓君²

(1. 哈尔滨工程大学信息与通信工程学院 哈尔滨 150001; 2. 中央民族大学信息工程学院 北京 100081)

摘要:现有睡眠分期方法存在特征提取不充分、类别间存在数据不平衡等问题,导致睡眠分期的精度不高。基于残差收缩网络设计高效的特征提取网络,同时,在损失函数中基于重加权思想设计了类别加权损失函数,通过调整损失函数有效解决了数据不平衡对分类精度的影响。实验结果表明,改进算法在 Sleep-EDF 数据集上的 Fpz-Cz、Pz-Oz 通道上,准确率分别为 85.4% 和 82.2%, MF_1 分别为 79.6% 和 75.4%,均高于基准算法和目前先进的对比算法,证明了算法的有效性和先进性。

关键词: 睡眠分期;残差收缩网络;类别加权损失函数;脑电信号;重加权思想

中图分类号: TH79 **文献标识码:** A **国家标准学科分类代码:** 510.40

Sleep EEG staging based on the residual shrinkage network

Chen Lingling¹, Bi Xiaojun²

(1. College of Information and Communication Engineering, Harbin Engineering University, Harbin 150001, China;
2. School of Information Engineering, Minzu University of China, Beijing 100081, China)

Abstract: For the existing staging methods, the accuracy is limited by insufficient feature extraction and class imbalance. To solve the problem, the residual shrinkage network is applied to design a convolutional neural network to extract feature efficiently. Meanwhile, the idea of re-weighting is used to design the loss function to address the problem that N1 stage gets low accuracy due to less samples. Finally, experiments are designed based on data of the Fpz-Cz and Pz-Oz channel in the Sleep-EDF dataset. The accuracy rates are 85.4% and 82.2%, respectively. The MF_1 values are 79.6% and 75.4%, respectively. Results show that the method achieves higher accuracy and MF_1 than the benchmark algorithm and current advanced comparison algorithms. It proves the effectiveness and advancement of the proposed algorithm.

Keywords: sleep stage; residual shrinkage network; class weighted loss function; electroencephalogram; re-weighting

0 引 言

睡眠分期是睡眠分析、评估的基础,在睡眠相关疾病的早期诊断和干预中起着至关重要的作用,目前已成为睡眠领域的研究热点。根据美国睡眠医学会制定的睡眠分期判读标准—AASM 标准^[1],完整的睡眠过程可以划分为清醒期(wake, W)、非快速动眼时期(non-rapid eye movements, NREM)和快速动眼期(rapid eye movements, REM),其中 NREM 根据不同时间的特征,又可以细分为 N1、N2、N3 期。

医学上睡眠分期通过对睡眠多导图中脑电

(electroencephalogram, EEG)、眼电、肌电等信号进行分析实现,但在采集多种生理信号过程中,受试者需要佩戴多种电极和设备,容易造成心理压力,进而影响睡眠情况。根据 AASM 标准,EEG 是睡眠分期判读的主要依据,所以从便携式应用的角度出发,利用单通道脑电数据进行睡眠分期研究逐渐成为了研究热点^[2]。

早期的睡眠分期方法主要通过 EEG 信号进行时域分析、频域和非线性分析来提取信号特征,再通过支持向量机等技术进行分类^[3],这种分类方法精度较低,泛化能力差。近年来随着人工智能技术的发展,深度学习模型在图像领域获得了突破性的进展,目前已成为基于 EEG 的睡眠分期研究中最有效的方法。其中,研究重点在于

解决模型设计问题和数据不平衡问题。在模型设计方面,已提出利用卷积神经网络提取信号的时不变特征、循环神经网络^[4]提取信号的时序特征,Supratak等^[5]设计多尺度卷积神经网络提取特征,然后利用双向长短时记忆网络提取时序特征,达到了0.82的准确率,在此基础上,为了充分提取信号中的特征,图像处理领域取得较好效果的深度学习模型如残差网络^[6]、深度可分离卷积网络^[7]等都被应用到了睡眠分期中,其中代表性的有Qu等^[8]利用残差网络提取信号的时不变特征,达到了0.843的准确率。分析现有研究成果准确率不高的原因,主要存在如下两个问题:1) EEG是一种低信噪比的信号,信号受噪声影响严重,上述研究成果提取到的特征仍含有大量的冗余信息,特征提取不充分将影响分期的准确率;2)在数据平衡方面,由于睡眠过程中N1期存在时间明显少于其他时期,造成睡眠数据中存在类别分布不均的问题,目前主要利用过采样的方法解决该问题,如随机过采样^[5]、MSMOTE^[9]、SMOTE^[10]等,但这种通过复制或生成少数类样本达到数据平衡的方法容易造成少数类别的过拟合,进而影响分类的精度,并且重平衡后的数据会破坏序列的时序关系,训练过程存在一定的难度,导

致少数类分类精度不高。

本文为了提高网络的特征提取能力,基于可以有效消除信号中冗余信息的残差收缩网络(residual shrinkage network, RSN)^[11]设计了高效的时不变特征提取网络;针对睡眠 EEG 数据中存在的类别不平衡的问题,引入了重加权思想,设计了加权损失函数;最后,在睡眠分期最常用的 Sleep-EDF 数据集上,进行 20 折交叉验证实验,证明了本文算法的有效性和先进性。

1 RSNSleepNet 睡眠分期算法

本文提出的 RSNSleepNet 睡眠分期算法首先设计了基于残差收缩网络的时不变特征提取网络,通过输入睡眠数据中的单通道 EEG 信号,获得 EEG 信号的高维时不变特征。然后,将其输入到时序特征提取网络中,提取信号的时序相关性。同时,为了解决睡眠数据中存在的类别不平衡问题,在原有序列交叉熵的基础上,引入重加权思想,重新设计了损失函数,并对网络模型进行端到端训练,有效解决了数据不平衡对分类精度的影响。本文的整体结构框架如图 1 所示。

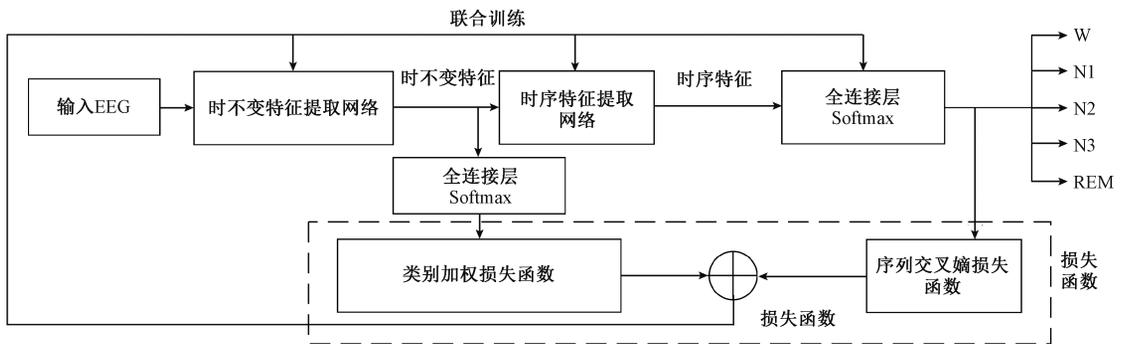


图1 整体框架

Fig. 1 The overall framework

1.1 时不变特征提取网络

EEG是由不同频率、不同幅值和不同形态的脑电波组成,具有很高的时变敏感性,极易被无关的噪声影响。特别是在信号采集过程中轻微的扰动或电极移位都可能受噪声的影响产生一定的冗余信息。2019年提出的残差收缩网络通过引入软阈值化函数,可有效地去除信号中噪声带来的冗余信息,提高特征提取的质量,目前已经在震动信号、语音信号等高噪声信号处理领域取得了显著的效果,但还没有在 EEG 特征提取方面应用。为了有效去除 EEG 的冗余信息,本文将采用残差收缩网络来设计时不变特征提取部分。

为此本文设计的时不变特征提取网络如图 2 所示,网络各层的参数为 $[C, P, /S]$,其中 C 代表输出的通道

数, P 代表卷积或池化尺度, S 代表步长。将整晚的睡眠 EEG 信号每隔 30 s 划分为一个睡眠样本,并且以 100 Hz 的频率进行采样,则一个睡眠样本的输入尺度为 $3\ 000 \times 1 \times 1$ 。

首先,利用卷积尺度为 30,步长为 6 的 1 维卷积提取原始信号的低维特征,在尽可能保留有效信息的前提下,降低特征的维度。由于睡眠样本中不同频带波形出现的时长决定了睡眠阶段,如 W 期的典型特征是频率为 8~13 Hz 的 α 波的占比总多于 50%,而 N3 期的典型特征是频率为 0.5~20 Hz 的 δ 波的占比大于 20%,因此为了充分地分析该信号,本文采用两个池化尺度不同的最大值池化层进行下采样操作,并对输出的特征进行融合。最大池化层并没有引入多余参数,能在降低计算量的前

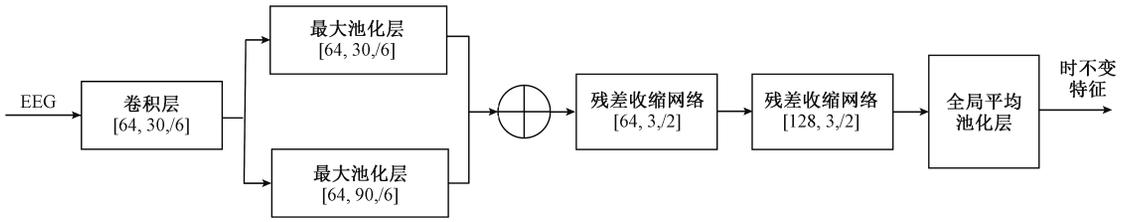


图 2 时不变特征提取网络

Fig. 2 The architecture of time-invariant feature extraction

前提下,提高模型对关键特征的提取能力。为了去除特征中的冗余信息,将融合后的特征输入到残差收缩网络中,增加网络的深度来提高网络拟合特征的能力,但层数过深容易出现梯度不稳定和过拟合的问题,特别针对 EEG 这种一维的信号,越容易出现过拟合,所以,本文设计的时不变特征提取网络中利用两个残差收缩模块去除冗余信息。并且为了在增加逐层学习能力的同时让每个网络层能学习到更丰富的特征,第 1 个残差收缩网络的输出通道数为 64,而第 2 个残差收缩网络的输出通道数增加为 128,通过增加网络的宽度,增加网络的特征学习能力。

残差收缩网络由残差网络、阈值学习网络和软阈值化函数组成。其中残差网络用于解决网络层数增加带来的模型退化问题,阈值学习网络可根据不同 EEG 样本中噪声的差异自适应调整阈值大小,软阈值化函数根据阈值去除冗余信息。其中 C 表示输出的通道数, W 为信号的尺度。其中软阈值化函数,是小波降噪算法中的核心步骤^[12],表达如下:

$$y = \begin{cases} x - \tau, & x > \tau \\ 0, & -\tau \leq x \leq \tau \\ x + \tau, & x < -\tau \end{cases} \quad (1)$$

式中: x 为卷积层学习的特征向量; τ 为阈值向量,其中元

素为接近 0 的正值; y 为降噪后的特征向量,通过软阈值化函数将 $\pm\tau$ 范围内的特征置为 0。通过不断消除冗余信息的影响,增强有效特征,提高特征提取能力。

1.2 时序特征提取网络

由于睡眠 EEG 数据是连续时间采集的样本,相邻样本间存在时序相关性,对当前样本预测时,不仅依靠该样本的特征,还可以根据先前或之后样本的结果对当前样本的预测结果进行修正。例如,当前样本为 N_1 期时,则下一样本的阶段很可能是 N_1 期或 N_2 期。

相较于普通的长短时记忆网络(long short-term memory, LSTM)只能从先前的信息中学到序列的转换规律,双向长短时记忆网络(bi-directional LSTM, Bi-LSTM)中增加了一个逆向传播的 LSTM,用于学习信息的逆向传播规律^[13],所以本文利用 Bi-LSTM 来学习样本间的时序相关性,进而提高分期的准确率,本文的时序特征提取网络结构如图 3 所示,其中 C_i 代表长度为 P 的子序列中第 i 个样本的时不变特征, $LSTM_L$ 和 $LSTM_R$ 分别代表学习前向和反向传播规则的 LSTM。同时为了能更充分的利用时不变特征,在序列学习部分,将时不变特征经全连接层后的特征与 Bi-LSTM 提取的特征融合,得到用于分类的时序特征。

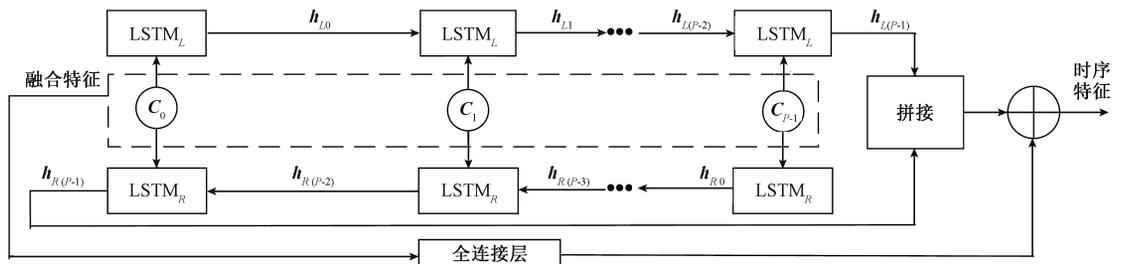


图 3 本文的时序特征提取网络

Fig. 3 The architecture of temporal feature extraction in this article

1.3 损失函数的改进

睡眠 EEG 的数据分布在不同类别之间还存在着数据分布不均匀的问题。如图 4 所示,根据睡眠阶段随时间的转换规则,每隔 30 s 作为一个样本划分数据集时, N_1 期的样本数量明显少于 N_2 期。

为了解决上述数据分布不均衡的问题,目前常用的方法是采用预训练-微调的两步训练法,先用重平衡数据预训练时不变特征提取部分,然后利用原始数据微调整个网络,这样可以解决一定的数据分布不均衡问题,但是容易造成少数类别样本的过拟合,导致睡眠分期的精度

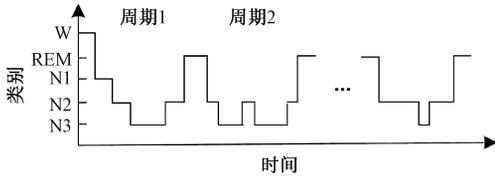


图4 睡眠转换规则

Fig. 4 The rule of sleep staging

有所下降。为此,本文从损失函数入手,在时不变特征部分设计了依据重加权思想^[14]设计的类别加权损失函数,通过增大少数类对损失函数的影响,来解决睡眠 EEG 数据不平衡的问题,进而提高睡眠分期中少数类的分类精度。

同时,为了避免两步训练因相同输入造成的过拟合问题,充分利用深层神经网络和并行计算的优势,简化训练过程的复杂度,本文算法将时不变特征提取网络和时序特征提取网络作为一个级联网络,分别将两部分的损失函数相加,作为整体网络的联合训练函数,对网络进行端到端的训练,如式(2)所示。

$$L_j = L_{wa} + L_s + L_r \quad (2)$$

式中: L_{wa} 为时不变特征部分的类别加权损失函数,用于解决数据分布不均衡的问题; L_s 为时序特征部分的序列交叉熵损失函数,用于学习连续样本间的时序相关性; L_r 为正则化项,用于防止过拟合。

类别加权损失函数如式(3),具体思路是赋予多数类较小的代价权值,来弱化多数类样本的影响,但由于样本数较多,特征较丰富,所以依然能使多数类样本得到充分训练;赋予少数类较大的代价权值,如果少数类样本被错误分类,较大的代价权值就会造成较大的损失,然而在模型训练过程中为了达到性能最优,就会不断向损失函数减小的方向优化,会相应的减少少数类的错分,进而缓解部分类别由于数目过少、训练不充分造成的准确率较低的问题。

$$L_{wa} = -\frac{1}{M} \sum_{c=1}^M y_c \cdot w \sum_{c=1}^N y_c \log(y_{cs}) \quad (3)$$

式中: $w = [w_1, w_2, w_3, w_4, w_5]$ 为代价权值向量, w_i 通过式(4)、(5)计算,其反比于各个睡眠阶段的样本数量; y_c 为样本标签值,为 one-hot 编码的形式; y_{cs} 由时不变特征经 softmax 得到; M 为时不变特征提取部分批处理的值。

$$P_i = \frac{\sum_{c=1}^N S_c}{S_i} \quad (4)$$

$$w_i = N \times \frac{P_i}{\sum_{c=1}^N P_c} \quad (5)$$

式中: N 为睡眠阶段数 5; S_i 为阶段 i 的样本数。

序列交叉熵损失函数 L_s , 如式(6)所示。

$$L_s = \frac{1}{P \times Q} \sum_{i=1}^P \sum_{j=1}^Q L'_e(i, j) \quad (6)$$

式中: Q 为时序特征提取部分批处理值; P 为 Bi-LSTM 输入子序列的长度,且满足 $P \times Q = M$; $L'_e(i, j)$ 代表第 i 个子序列的第 j 个样本的交叉熵,通过式(7)计算。

$$L'_e = \sum_{c=1}^N y_{i,j,c} \log(y_{i,j,cs}) \quad (7)$$

式中: $y_{i,j,c}$ 代表样本 (i, j) 的标签值; $y_{i,j,cs}$ 代表时序特征经 Softmax 的输出。

综上,本文设计的损失函数既缓解了数据类别分布不均带来的少数类精度较差的问题,又充分学习了时序特征提取网络提取的时间序列相关性,可有效提高睡眠分期的精度。

2 实验验证

为了验证本文创新工作的有效性和先进性,这里进行了两个方面的实验:1) 分别验证本文提出的时不变特征提取网络的有效性以及改进的损失函数的有效性;2) 将本文提出的 RSNSleepNet 算法与目前表现性能最好的 4 种睡眠分期方法进行对比,验证本文算法的先进性。

2.1 数据集

本文采用睡眠分期最常用的 Sleep-EDF 数据集^[15], 其中包含 20 个人的睡眠记录,除一个受试者丢失了一晚的睡眠记录外,其余每个人有两晚的睡眠记录。其中的睡眠数据是以多导图 (polysomnogram, PSG) 呈现,每个 PSG 中分别包含两个通道的 EEG 信号,一个通道的眼电和肌电^[16]。由于 Fpz-Cz 和 Pz-Oz 通道的数据更能有效的反映 EEG 中睡眠阶段的转换规律,能有效的代替国际标准导联系统推荐的 C4-A1 和 C3-A2^[17], 所以 Sleep-EDF 数据集中分别包含 Fpz-Cz 和 Pz-Oz 通道的数据。由于电极放置位置的不同,两通道数据有很大区别。为了睡眠分期的便携式发展,研究基于单通道 EEG 的睡眠分期非常有意义,在实验中分别选取 Fpz-Cz、Pz-Cz 通道的 EEG 进行实验,采样频率为 100 Hz。每一个样本都已由睡眠专家标记为 W、N1、N2、N3、N4、REM,根据 AASM 标准将 N3 和 N4 合并为 N3。最终数据分布如表 1 所示。

表1 数据集样本分布情况

Table 1 Distribution of dataset set

通道	W	N1	N2	N3	REM	合计
Fpz-Cz	7 927	2 804	17 799	5 703	7 717	41 950
Pz-Oz	7 927	2 804	17 799	5 703	7 717	41 950

2.2 实验条件

本文所有实验运行平台如表2所示。

表2 本文实验环境配置

Table 2 Experimental configuration

环境	配置
操作系统	Ubuntu 16.04
处理器	Inter ^B Core TM i74790CPU@3.60 GHz
显卡	GeForce RTX 980Ti
内存	8 GB
开发工具	Tensorflow 1.14.0 Python3.5.4

在训练过程中,采用 Adam 优化函数,学习率选为 0.001, batch size 为 250, 序列学习过程中批处理为 25, 子序列长度为 10。为了防止过拟合,每个全连接层后接 dropout 层,丢失率为 0.5。Fpz-Cz 通道、Pz-Oz 通道分别进行睡眠分期最常用的 20 折交叉验证实验,根据受试者的差异,按 19:1 划分训练集和验证集,即采用 19 个受试者的睡眠记录进行训练,用其余一名受试者的睡眠记录验证模型性能,重复 20 次训练验证。

2.3 评价指标

分别采用睡眠分期领域普遍采用的 MF_1 (macro-averaging F_1 -score) 分数、整体准确率 (overall-accuracy, A_{cc}) 对改进算法的整体性能进行评价。

表3 算法有效性验证结果

Table 3 The result of algorithm validity Verification

算法	Fpz-Cz 通道						Pz-Oz 通道							
	A_{cc}	MF_1	各个类别 F_1					A_{cc}	MF_1	各个类别 F_1				
			W	N1	N2	N3	REM			W	N1	N2	N3	REM
DeepSleepNet	82.0	76.9	84.7	46.6	85.9	84.8	82.4	79.8	73.1	88.1	37.0	82.7	77.3	80.3
RSNSleepNet ¹	84.7	78.3	88.4	44.5	88.1	86.3	84.4	81.1	74.3	85.3	41.1	85.2	77.6	82.2
RSNSleepNet	85.4	79.6	89.2	48.4	88.5	86.8	85.1	82.2	75.4	87.7	41.8	86.0	79.1	82.2

从表3可以看出,在 Fpz-Cz 通道上,RSNSleepNet¹ 得到的整体准确率为 0.847, MF_1 为 0.783, 与 DeepSleepNet 相比整体准确率提高了 3.3%, MF_1 提高了 1.8%; 在 Pz-Oz 通道上 RSNSleepNet¹ 得到的整体准确率为 0.811, MF_1 为 0.743, 与 DeepSleepNet 相比,整体准确率提高了 1.6%, MF_1 提高了 1.6%。进而证明了本文利用残差收缩网络设计的时不变特征提取网络无论是在 Fpz-Cz 通道还是 Pz-Oz 通道上都可以更高效的提取到睡眠 EEG 的时不变特征,提高分期的精度,进而验证了该部分的有效性。

在 Fpz-Cz 通道上,RSNSleepNet 实验得到的整体准确率为 0.854, MF_1 为 0.796, 与 RSNSleepNet¹ 相比,整体

$$A_{cc} = \frac{\sum_{i=1}^c T_{P_i}}{N} \quad (8)$$

$$MF_1 = \frac{\sum_{i=1}^c F_{li}}{C} \quad (9)$$

式中: N 代表样本总数; C 代表类别总数; F_{li} 代表类别 i 的 F_1 分数,由式(10)计算得到。

$$F_{li} = \frac{2P_i R_i}{P_i + R_i} \quad (10)$$

式中: $P_i = \frac{T_{P_i}}{T_{P_i} + F_{P_i}}$, $R_i = \frac{T_{P_i}}{T_{P_i} + F_{N_i}}$, T_{P_i} 代表对于类别 i 被正确分类的样本数, F_{P_i} 代表被错误预测为第 i 类的样本数, F_{N_i} 代表类别 i 被错误预测为其他类别的样本数。

2.4 算法有效性验证

本文针对睡眠 EEG 中存在噪声和数据分布不平衡的问题,分别从特征提取网络和损失函数入手进行了改进。为了验证本文设计的时不变特征提取网络和损失函数改进的有效性,在基准算法 DeepSleepNet 的基础上分别设计 RSNSleepNet¹ 和 RSNSleepNet 实验,其中 RSNSleepNet¹ 实验将 DeepSleepNet 中的 CNN 部分替换为了本文提出的时不变特征提取网络; RSNSleepNet 实验为在 RSNSleepNet¹ 的基础上引入了设计的损失函数,并对网络模型进行端到端训练。在 Fpz-Cz 和 Pz-Oz 通道上的结果对比如表3所示。

准确率提高了 0.8%, MF_1 提高了 1.7%; 在 Pz-Oz 通道上,整体准确率为 0.822, MF_1 为 0.754, 与 RSNSleepNet¹ 相比,整体准确率提高了 1.4%, MF_1 提高了 1.5%。无论是在 Fpz-Cz 通道上还是 Pz-Oz 通道上,本文设计的损失函数都有效地缓解了数据分布不均的影响,验证了本文设计的损失函数的有效性。

为了进一步衡量模型的复杂度,本文算法与基准算法在计算量和参数量的对比结果如表4所示。其中计算量由 FLOPS 进行衡量。通过对比发现,本文设计的网络模型中由于残差收缩网络的引入可以更高效的提取数据特征,并且模型的计算量降为了原来的 1/4, 参数量降为

了原来的 1/2,说明本文设计的模型在一定程度上减少了模型的复杂度,进而证明了算法的有效性。

表 4 模型复杂度对比结果

Table 4 The result of model complexity

模型	FLOPS/(次/s)	参数量
DeepSleepNet	1.00×10^{11}	2.26×10^7
RSNSleepNet	2.29×10^{10}	1.07×10^7

表 5 算法先进性验证结果

Table 5 The result of the algorithm advanced verification

算法	Fpz-Cz 通道							Pz-Oz 通道							%
	A _{CC}	MF ₁	Per Class F ₁					A _{CC}	MF ₁	Per Class F ₁					
			W	N1	N2	N3	REM			W	N1	N2	N3	REM	
U-Time	-	79.0	87.0	52.0	86.0	84.0	84.0	-	-	-	-	-	-	-	-
Residual	80.1	79.0	85.9	38.7	84.4	82.5	76.5	79.2	71.1	87.1	30.1	83.3	79.1	75.9	
IITNet	83.6	76.5	-	-	-	-	-	-	-	-	-	-	-	-	
ResMHA	84.3	79.0	90.2	48.3	87.8	85.6	83.0	80.7	74.1	87.2	36.8	85.2	81.3	80.1	
RSNSleepNet	85.4	79.6	89.2	48.4	88.5	86.8	85.1	82.2	75.4	87.7	41.8	86.0	79.1	82.2	

从表 5 看出,在 Fpz-Cz 通道上,本文算法无论是整体准确率还是 MF₁ 均高于对比算法,并且与目前表现最好的算法 ResMHA 相比,整体准确率比 ResMHA 的准确率高 1.3%,MF₁ 高 0.8%。在 Pz-Oz 通道上,本文算法的整体准确率和 MF₁ 也都高于对比算法,分别比 ResMHA 高 1.9% 和 1.8%,充分验证了本文算法具有更好的睡眠分期效果。

2.6 存在的问题

分别在 Fpz-Cz、Pz-Oz 通道预测得到的混淆矩阵如图 5 所示,混淆矩阵中列表示实际类别,行表示预测类别,颜色越深代表预测为该类别的样本数越多。

2.5 算法先进性验证

为了验证本文算法先进性,与 4 种先进算法进行对比实验,分别是 U-time^[18]、Residual^[6]、IITNet^[19] 和 ResMHA^[8]。其中 ResMHA 是目前性能最好的算法。U-Time、IITNet 没有在 Pz-Oz 通道上进行实验,验证本文算法在 Pz-Oz 通道的先进性部分仅与 Residual 和 ResMHA 进行对比。本文提出的 RSNSleepNet 在 Fpz-Cz 和 Pz-Oz 通道上与上述算法的对比结果如表 5 所示。

从混淆矩阵中可以看出,无论是 Fpz-Cz 通道还是 Pz-Oz 通道,本文算法对于大部分样本都可以得到正确的分类,并且对于大多数类别如 W、N1、N3 期的样本错分主要出现在相邻的时期,主要是因为睡眠阶段转换时期的样本存在特征重合,睡眠专家进行标记时转换时期的样本难以人为区分,计算机学习到的转换时期的样本特征较模糊,所以错分为当前阶段的相邻阶段。并且结合 Sleep-EDF 中各个阶段的数据分布情况,由于 N1 期的样本数量明显少于其他时期,N1 期的 F₁ 低于其他阶段,虽然相较于目前现有的睡眠分期算法,本文改进的损失函数缓解了类别分布不均衡造成的少数类样本分类精度较差的问题,但由于样本数量过少,所以准确率还是与其他阶段有一定的差别。

		预测类别				
		W	N1	N2	N3	REM
标签类别	W	6776	570	288	38	255
	N1	232	1224	791	24	533
	N2	115	283	16062	769	570
	N3	14	4	659	5013	13
	REM	123	171	685	4	6731

(a) Fpz-Cz通道混淆矩阵
(a) Confusion matrix of Fpz-Cz

		预测类别				
		W	N1	N2	N3	REM
标签类别	W	6775	480	233	23	426
	N1	398	985	739	23	659
	N2	177	326	15493	762	1041
	N3	16	5	1281	4268	133
	REM	149	111	479	16	6962

(b) Pz-Oz通道混淆矩阵
(b) Confusion matrix of Pz-Oz

图 5 混淆矩阵

Fig. 5 Confusion matrix

3 结 论

针对 EEG 的低信噪比问题,利用残差收缩网络设计一种能够有效去除 EEG 中冗余信息的时不变特征提取网路,并利用 Bi-LSTM 提取 EEG 的样本间的时间相关性,有效提高了特征提取的质量。同时,利用重加权思想设计了损失函数,训练过程采用联合损数函数对网络进行端到端的训练,较好解决了睡眠数据分布不均衡的问题。本文分别在 Sleep-EDF 中 Fpz-Cz、Pz-Oz 通道上进行了 20 折交叉验证实验,通过与基准算法 DeepSleepNet 对比验证了本文创新点的有效性,并通过与目前最好的几种算法对比,本文提出的 RSNSleepNet 算法无论是在整体准确率还是 MF₁ 都优于对比算法,进而验证了本文算法的先进性。

参考文献

- [1] 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.
- [2] 张远. 面向睡眠健康的感知、计算和干预[J]. *科学通报*, 2022, 67(1): 27-38.
ZHANG Y. Sensing, computing and intervention for sleep health [J]. *Chinese Science Bulletin*, 2022, 67(1): 27-38.
- [3] 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.
- [4] SM I N, ZHU X, CHEN Y, et al. Sleep stage classification based on EEG, EOG, and CNN-GRU deep learning model[C]. *IEEE 10th International Conference on Awareness Science and Technology (iCAST)*, 2019: 1-7.
- [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] 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]. *IEEE EMBS International Conference on Biomedical & Health Informatics (BHI)*, 2019: 1-5.
- [7] FERNANDEZ-BLANCO E, RIVERO D, PAZOS A. EEG signal processing with separable convolutional neural network for automatic scoring of sleeping stage [J]. *Neurocomputing*, 2020, 410: 220-228.
- [8] QU W, WANG Z, HONG H, 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.
- [9] 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 S L, HAO J W, PAN L M. An automatic sleep staging method based on CNN-BiLSTM [J]. *Transactions of Beijing Institute of Technology*, 2020, 40(7): 746-752.
- [10] 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.
- [11] ZHAO M, ZHONG S, FU X, et al. Deep residual shrinkage networks for fault diagnosis [J]. *IEEE Transactions on Industrial Informatics*, 2019, 16(7): 4681-4690.
- [12] 宋子豪, 程伟, 彭岑昕, 等. 基于 CWD 和残差收缩网络的调制方式识别方法 [J]. *系统工程与电子技术*, 2021, 43(11): 3371-3379.
SONG Z H, CHENG W, PENG C X, et al. Modulation recognition method based on CWD and residual shrinkage network [J]. *Systems Engineering and Electronics*, 2021, 43(11): 3371-3379.
- [13] 殷礼胜, 孙双晨, 魏帅康, 等. 基于自适应 VMD-Attention-BiLSTM 的交通流组合预测模型 [J]. *电子测量与仪器学报*, 2021, 35(7): 130-139.
YIN L SH, SUN SH CH, WEI SH K, et al. Traffic flow combination prediction model based on adaptive VMD-attention-BiLSTM [J]. *Journal of Electronic Measurement and Instrumentation*, 2021, 35(7): 130-139.
- [14] 董勋, 郭亮, 高宏力, 等. 代价敏感卷积神经网络: 一种机械故障数据不平衡分类方法 [J]. *仪器仪表学报*, 2019, 40(12): 205-213.
DONG X, GUO L, GAO H L, et al. Cost sensitive convolutional neural network: A classification method for imbalanced data of mechanical fault [J]. *Chinese Journal*

of Science Instrument, 2019, 40(12): 205-213.

- [15] KEMP B, ZWINDERMAN A H, TUK B, et al. Analysis of a sleep-dependent neuronal feedback loop: The slow-wave microcontinuity of the EEG[J]. IEEE Transactions on Biomedical Engineering, 2000, 47(9): 1185-1194.
- [16] GOLDBERGER A L, AMARAL L A N, 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.
- [17] SWEDEN B, KEMP B, KAMPHUISEN H A C, et al. Alternative electrode placement in (automatic) sleep scoring (Fpz-Cz/Pz-Oz versus C4-A1/C3-A2) [J]. Sleep, 1990, 13(3): 279-283.
- [18] PERSLEV M, JENSEN M, DARKNER S, et al. U-time: A fully convolutional network for time series segmentation applied to sleep staging[C]. Proceedings of the Advances in Neural Information Processing Systems (NeurIPS), 2019.
- [19] 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.

作者简介



陈玲玲, 2019年于哈尔滨工程大学获得学士学位, 现为哈尔滨工程大学硕士研究生, 研究方向为生医学信号处理和深度学习。

E-mail: chenlingling@hrbeu.edu.cn

Chen Lingling received her B.Sc. degree from Harbin Engineering University in 2019. She is currently a M.Sc. candidate at Harbin Engineering University. Her main research interests include biomedical information processing and deep learning.



毕晓君(通信作者), 1987年于哈尔滨船舶工程学院获得学士学位, 1990年于哈尔滨工业大学获得硕士学位, 2006年于哈尔滨工程大学获得博士学位, 现为中央民族大学教授, 主要研究方向为深度学习的理论与应用方面

用方面

E-mail: bixiaojun@hrbeu.edu.cn

Bi Xiaojun (Corresponding author) received her B.Sc. degree from Harbin Engineering University in 1987, M.Sc. degree from Harbin Institute of Technology in 1990, and Ph.D. degree from Harbin Engineering University in 2006. She is currently a professor and a Ph.D. advisor at Minzu University of China. Her main research is machine learning.