

一种基于 EOG 的睡眠分期算法研究

梁文虎¹ 杨其宇¹ 王振学¹

LIANG Wenhui YANG Qiyu WANG Zhenxue

摘要

睡眠质量影响着人类的身体健康与生活质量, 准确的睡眠分期是睡眠质量评估的重要依据。针对眼电信号中的规律性, 文章提出了一种用于实现睡眠分期的基于 EOG 的深度学习网络 -AMSTNet。首先, 采用 3 个不同尺度的一维卷积网络进行 EOG 信号特征提取; 其次, 构建一个自适应特征校准模块, 动态进行特征权重的选取校准; 接着, 采用双向门控循环单元学习各睡眠阶段间的时间序列规则; 最后, 通过公开数据集 Sleep-EDF 验证模型实现睡眠分期的效果。实验结果表明, 所提模型在利用 EOG 信号进行睡眠分期中有较好的性能, 用 EOG 做睡眠分期是可行的。

关键词

眼电信号 (EOG); 睡眠分期; 自适应特征提取; 卷积神经网络; 双向门控循环单元

doi: 10.3969/j.issn.1672-9528.2025.06.005

0 引言

睡眠是人类一项基本的生理活动。近年来, 利用脑电信号进行自动睡眠分期的算法取得了较好的性能。如 Goshtasbi 等人^[1]采用全卷积神经网络对单通道 EEG 进行睡眠分期, 准确率为 84.8%。Gabriel-alexandru 等人^[2]采用 CNN-LSTM 网络同样对单通道 EEG 进行睡眠分类, 准确率为 88.8%。Seifpour 等人^[3]采用时域特征统计 SBLE 网络对单通道 EEG 数据进行睡眠分类, 准确率达到 90.6%。然而, 脑电信号的采集过程相对专业与繁琐。相比之下, 眼电信号的采集相对简单方便, 并且不需要经过专业培训也能进行信号的正确采集。这为设计便携、可穿戴的自动睡眠分期系统提供了可能性^[4]。研究表明, 眼电信号 (EOG) 是一种潜在的睡眠分期

方式^[5]。这是由于 EOG 信号能反映眼睛的活动情况, 并且眼电信号与脑电信号具有高度的相似性^[6]。Fan 等人^[7]采用 CNN-RNN 网络对 EOG 信号进行特征提取与序列学习以进行睡眠分类, 在 MASS 数据集和 SleepEDF 数据集上分别获得准确率为 81.2% 和 76.3%。利用眼电信号做睡眠分期在便携性以及经济性方面优势较为明显。

本文提出一种深度学习网络模型 (adaptive multi-scale temporal network, AMSTNet), 用于对眼电信号进行特征提取与学习, 实现自动睡眠分期。首先, 针对眼电信号多层次特征提取问题, 本文采用 3 种尺度的一维卷积神经网络进行提取不同维度的特征。其次, 构建一个自适应特征校准模块, 通过全局特征信息对各通道特征进行动态加权, 有效提升模型对关键特征的关注。最后, 使用双向门控循环单元 (bidirectional gate recurrent unit, Bi-GRU) 捕捉学习各睡眠

1. 广东工业大学 广东广州 511400

OL].(2023-04-17)[2024-10-03].<https://doi.org/10.48550/arXiv.2304.08085>.

[16] WEI X, CUI X Y, CHENG N, et al. ChatIE: zero-shot information extraction via chatting with ChatGPT[EB/OL]. (2024-05-27)[2024-08-19].<https://doi.org/10.48550/arXiv.2302.10205>.

[17] GUO Y C, LI Z X, JIN X L, et al. Retrieval-augmented code generation for universal information extraction[C]//Natural Language Processing and Chinese Computing. Berlin: Springer, 2024: 30-42.

[18] BI Z, CHEN J, JIANG Y N, et al. CodeKGC: code language

model for generative knowledge graph construction[J].ACM transactions on asian and low-resource language information processing, 2024, 23(3): 1-16.

【作者简介】

程楠楠 (1987—), 女, 江苏南通人, 博士研究生, 高级工程师、讲师, 研究方向: 知识图谱与大语言模型、智能医疗, email:chengnalu@126.com。

魏璐露 (1995—), 女, 江西南昌人, 硕士, 高级工程师、助教, 研究方向: AI 应用研究、生信大数据。

(收稿日期: 2024-12-30 修回日期: 2025-04-29)

阶段之间的时间序列信息与转换规则。实验结果表明,该方法能从 EOG 信号中获得较好的睡眠分期性能。

1 AMSTNet 模型

本文提出的 AMSTNet 模型结构如图 1 所示。模型主要由 4 部分组成:用于充分提取原始 EOG 信号的三尺度 EOG 睡眠特征学习模块、用于强调重要特征的自适应特征校准模块、用于进行时序性特征提取学习的 Bi-GRU 模块和 Softmax 分类器。




图 1 AMSTNet 网络结构图

1.1 基于 EOG 的睡眠特征学习模块

本文设计了一种三尺度的一维 CNN 来充分提取 EOG 信号的特征。具体来说,三尺度 CNN 网络可分为局部特征提取模块、中尺度特征提取模块和全局特征提取模块。其中,局部特征提取模块用较小的卷积核与较短的步幅注重于短时间的信号特征提取,全局特征提取模块采用较大的卷积核与较长的步幅注重于长时间的信号特征提取,而中尺度特征提取模块则是对前两个模块进行补充,采用适中的卷积核与步长进行特征提取。每个特征提取模块都由 4 个一维卷积层、2 个最大池化层和 1 个 dropout 层组成。并且,每个卷积层均采用以下操作:数据先经过一维卷积层,再进行批量归一化操作并采用 ReLU 作为激活函数。整体特征提取过程用公式表示为:

$$f_{it} = F_i(a_t) \quad (1)$$

$$z_t = f_{1t} \oplus f_{2t} \oplus f_{3t} \quad (2)$$

式中: $z_t \in \mathbb{R}^{C \times T}$ 表示该特征提取模块得到的特征向量,其中 C 表示拼接后的总通道数, T 表示时间步长; a_t 表示第 t 个 30 s 的脑电信号片段; $F_i(a_t)$ 表示第 i 个卷积网络从 a_t 提取的特征输出; $f_{it} \in \mathbb{R}^{C_i \times T}$ 表示第 i 个卷积网络提取的特征向量; C_i 表示第 i 个卷积网络输出通道数; z_t 表示通过拼接三路特征向量 f_{1t} 、 f_{2t} 、 f_{3t} 得到的完整特征; $\oplus$ 表示特征拼接操作符,用于组合不同卷积网络的输出。

1.2 自适应特征校准模块

本文设计了一种包含残差连接的自适应特征提取模块,来动态校准调整 EOG 信号突出特征的权重,抑制冗余特征,

提升特征表达能力。并且引入残差连接以保留原始特征信息能够缓解过拟合现象,提升模型训练的稳定性。具体来说,首先将前一模块提取到的特征 z_t 依次通过两个一维卷积网络进行先降维后升维的操作,进一步融合提取各通道的特征,增强通道间的表示能力。其中,两层卷积的先降维操作能减少计算量,后升维操作使特征恢复到原始通道数,从而确保信息的完整性。具体过程用公式表示为:

$$z_t^{(1)} = \text{ReLU}(\text{Conv1D}_1(z_t)) \quad (3)$$

$$z_t^{(2)} = \text{ReLU}(\text{Conv1D}_2(z_t^{(1)})) \quad (4)$$

式中: $z_t^{(1)} \in \mathbb{R}^{C' \times T}$ ($C' < C$) 表示降维后的特征输出; $z_t^{(2)} \in \mathbb{R}^{C \times T}$ 表示升维后的特征输出。

然后,对升维后得到的特征 $z_t^{(2)}$ 进行时间维度上的全局池化,得到全局描述变量 $s \in \mathbb{R}^C$,用公式表示为:

$$s = \frac{1}{T} \sum_{t=1}^T z_t^{(2)}(c, t), c = 1, 2, \dots, C \quad (5)$$

接着,利用两层全连接网络对通道特征进行建模,生成动态通道权重 $e \in \mathbb{R}^C$,如式(6)所示。再根据通道权重 e 对特征 $z_t^{(2)}$ 进行校准,得到校准后的特征 $\tilde{z}_t \in \mathbb{R}^{C \times T}$,如公式(7)所示。

$$e = \sigma(W_2 \cdot \delta(W_1 \cdot s)) \quad (6)$$

$$\tilde{z}_t(c, t) = e(c) \cdot z_t(c, t) \quad (7)$$

式中: W_1 、 W_2 为全连接层的权重; $\delta(\cdot)$ 与 $\sigma(\cdot)$ 分别为 ReLU 激活函数与 Sigmoid 激活函数; $c = 1, 2, \dots, C$; $t = 1, 2, \dots, T$ 。

最后,引入残差连接以保留原始特征信息,将校准后的特征 $\tilde{z}_t$ 与原始特征 z_t 通过残差连接进行融合,得到最终输出特征 $\hat{z}_t \in \mathbb{R}^{C \times T}$,其公式为:

$$\hat{z}_t = \tilde{z}_t + z_t \quad (8)$$

1.3 时序性特征提取学习模块

EOG 信号是非平稳的时间序列数据,具有明显的时间依赖性和序列特征。为了捕捉信号在时间维度上的前后关联性,本文采用 Bi-GRU 网络结构来对序列进行完整性建模。其中, Bi-GRU 主要由输入层、前向 GRU、后向 GRU 和输出层组成^[8],其网络结构如图 2 所示。




图 2 Bi-GRU 网络结构图

假设输入特征序列为 $X = [x_1, x_2, \dots, x_t]$,其中 $x_t \in \mathbb{R}^C$ 表示第 t 个时间步的输入特征。即前向 GRU 和后向 GRU 分别通过式(9)(10)计算前向隐藏状态 $\bar{h}_t$ 与后向隐藏状态 $\bar{h}_t$ 。

然后将前向和后向隐藏状态加权连接起来获得双向特征表示 h_t , 用公式表示为:

$$\tilde{h}_t = \text{GRU}_f(x_t, \tilde{h}_{t-1}) \quad (9)$$

$$\tilde{h}_t = \text{GRU}_b(x_t, \tilde{h}_{t+1}) \quad (10)$$

$$h_t = W_1 \times \tilde{h}_t \parallel W_2 \times \tilde{h}_t \quad (11)$$

式中: W_1 、 W_2 表示网络权重; $\parallel$ 表示向量连接操作。

接着, 将合并后的状态 h_t 接入到全连接层 (FC) 中, 以进行特征分类空间映射得到 o_t , 最后, 应用 SoftMax 分类器进行睡眠阶段分类, 用公式表示为:

$$o_t = \text{FC}(h_t) \quad (12)$$

1.4 损失函数

针对 EOG 信号类别不平衡问题, 本文采用带权重的交叉熵损失函数, 以提升对少数类的关注度。该损失函数通过对少数类加大权重, 能有效缓解类别不平衡对模型训练的负面影响。具体来说, 假设数据集分为 C 个类别, 每个类别的占比为 p_c , 则权重 w_c 定义为:

$$w_c = \frac{1}{p_c} \quad (13)$$

式中: $p_c = N_c/N$, N_c 是类别 c 的样本数量, N 是总样本数量。

当类别数量越少时, 对应的权重 w_c 就越大, 反之亦然。基于权重的交叉熵损失函数定义为:

$$\ell = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C w_c \cdot y_{i,c} \cdot \log(\hat{y}_{i,c}) \quad (14)$$

式中: $y_{i,c}$ 是样本 i 的真实标签; $\hat{y}_{i,c}$ 是模型对样本 i 的类别 c 的预测概率; w_c 是类别 c 的权重。

2 实验与结果分析

2.1 数据集

本文采用的睡眠数据来自公开数据集 Sleep-EDF Database Expanded (Version 2)。该数据集包含了 197 例受试者整夜的 PolySomnoGraphic 睡眠记录, 其中有 153 例是完全健康的受试者 (SC* 文件, SC = sleep cassette), 有 44 例是轻度入睡困难的受试者 (ST* 文件, ST=sleep telemetry)。每例受试者都采集了 EEG 信号、水平 EOG 信号、EMG 信号和进行事件标记。本文采用数据集的 153 例健康者的水平 EOG 数据, 该通道数据的采样率为 100 Hz。数据集的各阶段样本数量如表 1 所示。

表 1 Sleep-EDF 中 153 例健康受试者的各睡眠阶段数

5 分类	W	N1	N2	N3	REM	总计
样本数	65 795	21 469	68 633	12 991	25 767	194 655
占比	33.08%	11.03%	35.26%	6.67%	13.24%	100%

2.2 数据预处理

因 EOG 信号睡眠类别数量不均衡, 如 N1 期样本数量少, W 期样本数量最多。这样就会导致模型在 N1 期识别准确率不高。因此, 本文针对此问题采取去除睡眠 W 期的部分数据, 只保留睡眠阶段前后 40 min 的 W 期时间。同时, 为去除 EOG 信号的干扰, 提高数据质量以及分析准确性, 本文采用 FIR 带通滤波器^[9]对 EOG 信号进行滤波处理。研究表明, 眼电信号的频率主要集中在 0~10 Hz 之间^[10], 据此本文滤波器的下限频率设为 0.1 Hz, 上限频率设为 35 Hz。这个滤波范围能最大限度保留 EOG 的有效信号, 并能够去除低频的基线漂移和高频的肌电、工频 (50/60 Hz) 噪声。

2.3 评价指标

本文采用准确率 (accuracy, Acc)、宏平均 F_1 分数 (macro-averaged F_1 -score, MF1) 和科恩卡帕系数 (cohen kappa, κ)^[11] 3 个指标来评估模型对各类睡眠阶段的分期性能。3 个指标定义分别用公式表示为:

$$\text{Acc} = \frac{1}{K} \sum_{i=1}^K \frac{N_{pi}}{N} \quad (15)$$

$$\text{MF1} = \frac{1}{K} \sum_{i=1}^K \frac{2 \cdot \text{precision}_i \cdot \text{recall}_i}{\text{precision}_i + \text{recall}_i} \quad (16)$$

$$\kappa = \frac{\text{Acc} - P_e}{1 - P_e} \quad (17)$$

式中: N_{pi} 表示第 i 类预测正确的样本数; N 表示总体样本数; K 表示样本总类别数; precision_i 和 recall_i 分别表示精确率和召回率; $P_e = (a_1 \cdot b_1 + a_2 \cdot b_2 + \dots + a_N \cdot b_N) / N \cdot N$ 是由各类睡眠阶段真实样本个数 $a_1, a_2, \dots, a_N$, 各类睡眠阶段预测样本个数 $b_1, b_2, \dots, b_N$ 与 N 计算得到。

2.4 睡眠分期实验结果与分析

本文采用 10 折交叉验证的方法, 基于眼电信号进行睡眠的五级分类, 并对模型的分类性能进行评估, 实验结果如表 2 所示。从表 2 中可以看出, 模型在 Sleep-EDF 数据集的睡眠五分类整体正确率为 80.7%, Kappa 系数 (κ) 为 73.3%, 表明模型在睡眠五分类上有良好一致性。

表 2 AMSTNet 的睡眠五分类结果

睡眠标签	Precision/%	Recall/%	F_1 /%
W	94.2	87.9	90.9
N1	39.1	56.4	46.2
N2	81.1	86.2	86.6
N3	75.4	57.6	65.3
REM	88.2	73.7	80.3
整体	Acc	MF1	κ
	80.7	73.3	73.2

模型在 W 期的识别准确率最高,达到 94.2%。其次是 N2 期,准确率为 81.1%。模型在 N1 期的识别准确率最低,仅有 39.1%。原因可能因 W 期的样本数据最多,并且此阶段的信号特征显著,易于模型识别,而 N1 期的样本数量最少并且此阶段特征不明显,容易与其他睡眠阶段混淆。模型的睡眠分期预测结果混淆矩阵如图 3 所示。




图 3 睡眠五分类结果混淆矩阵

3 结语

本文针对传统 EEG 信号不便应用于便携式睡眠分析系统的问题,提出一种基于易于采集的 EOG 信号进行睡眠分期的 AMSTNet 模型,主要包括三尺度特提取模块、自适应特征校准、时序特征提取学习模块与分类器。针对 EOG 信号各阶段数量不均衡问题,通过减少睡眠阶段的 W 期的时长以及采用带权重的交叉熵损失函数,降低类别失衡带来的影响;此外,采用 FIR 带通滤波器进一步提升 EOG 信号质量。通过实验表明,该模型能有效应用于 EOG 的睡眠分期,以及 EOG 在开发轻量级睡眠监测设备领域具有巨大潜力。

在后续研究中,可以对整体数据集进行数据增强处理,以及可以加入小波分析进一步提升 EOG 信号质量,改善模型在 N1 时期分类性能。同时,可以对模型特征提取结构和时序特征提取结构进行改进,进一步提高对 EOG 特征提取与学习能力,提升模型的睡眠分类准确率。

参考文献:

- [1] GOSHTASBI N, BOOSTANI R, SANEI S. SleepFCN: a fully convolutional deep learning framework for sleep stage classification using single-channel electroencephalograms[J]. IEEE transactions on neural systems and rehabilitation engineering, 2022, 30: 2088-2096.
- [2] GABRIEL-ALEXANDRU V, MIHAELA-RUXANDRA L. Deep learning for sleep staging using EEG signals[C/OL]. // 2024 International Symposium on Electronics and Telecommunications (ISETC). Piscataway: IEEE, 2024[2024-09-02]. <https://ieeexplore.ieee.org/document/10797312>. DOI:

10.1109/ISETC63109.2024.10797312.

- [3] SEIFPOUR S, NIKNAZAR H, MIKAEILI M, et al. A new automatic sleep staging system based on statistical behavior of local extrema using single channel eeg signal[J]. Expert systems with applications, 2018, 104: 277-293.
- [4] IMTIAZ S A. A systematic review of sensing technologies for wearable sleep staging[J]. Sensors, 2021, 21(5): 1562.
- [5] VIRKKALA J, HASAN J, VARRI A, et al. Auto-matic sleep stage classification using two-channel electro-oculography[J]. Journal of neuroscience methods, 2007, 166(1): 109-115.
- [6] ZHU H Y, FU C, SHU F, et al. The effect of coupled electroencephalography signals in electrooculography signals on sleep staging based on deep learning methods[J]. Bioengineering, 2023, 10(5): 573.
- [7] FAN J H, SUN C L, LONG M, et al. EOGNET: a novel deep learning model for sleep stage classification based on single-channel EOG signal[EB/OL]. (2021-07-12)[2024-06-12]. <https://doi.org/10.3389/fnins.2021.573194>.
- [8] ZHANG Z W, DONG Z K, LIN H P, et al. An improved bidirectional gated recurrent unit method for accurate state-of-charge estimation[J]. IEEE access, 2021, 9: 11252-11263.
- [9] PANT A, KUMAR A, VERMA C, et al. Comparative exploration on EEG signal filtering using window control methods[J]. Results in control and optimization, 2024, 17: 100485.
- [10] VENKATARAMANAN S, PRABHAT P, CHOUDHURY S R, et al. Biomedical instrumentation based on electrooculogram (EOG) signal processing and application to a hospital alarm system[C/OL]. // Proceedings of 2005 International Conference on Intelligent Sensing and Information Processing. Piscataway: IEEE, 2005[2024-06-11]. <https://ieeexplore.ieee.org/document/1529512>. DOI: 10.1109/ICISIP.2005.1529512.
- [11] 唐万, 胡俊, 张晖, 等. Kappa 系数: 一种衡量评估者间一致性的常用方法(英文)[J]. 上海精神医学, 2015, 27(1): 62-67.

【作者简介】

梁文虎(1998—), 男, 广东茂名, 硕士, 研究方向: 模式识别、生物信号处理。

杨其宇(1977—), 男, 广东湛江人, 博士, 副教授, 研究方向: 智能控制与数字信号处理。

王振学(1998—), 男, 广东湛江人, 硕士, 研究方向: 电磁系统建模和优化、生物信号处理。

(收稿日期: 2024-12-30 修回日期: 2025-05-09)