

朱逵, 苗敏敏, 胡文军, 等. 多特征融合的脑电警觉度估计方法[J]. 智能计算机与应用, 2025, 15(1): 32-37. DOI: 10.20169/j.issn.2095-2163.250105

## 多特征融合的脑电警觉度估计方法

朱 逵<sup>1</sup>, 苗敏敏<sup>1,2</sup>, 胡文军<sup>1,2</sup>, 王士同<sup>3</sup>

(1 湖州师范学院 信息工程学院, 浙江 湖州 313000; 2 浙江省现代农业资源智慧管理与应用研究重点实验室, 浙江 湖州 313000; 3 江南大学 人工智能与计算机学院, 江苏 无锡 214000)

**摘要:** 传统的脑电警觉度识别通常只提取时域、频域或非线性其中一种类型特征, 导致警觉度估计的准确度不高, 本文提出了多特征融合的脑电警觉度估计方法。首先, 将脑电信号进行预处理, 随后提取时域、频域和非线性等多种特征, 进一步利用卡方检验进行特征选择; 其次, 将选择后的特征分别输入不同分类器进行警觉度估计; 最后, 使用 SEED-VIG 数据集进行实验, 对本文所提方法进行验证。实验结果表明, 多特征融合的脑电警觉度估计方法具有较好的效果。

**关键词:** 脑电信号; 警觉度; 多特征融合; 卡方检验

中图分类号: TN911.6

文献标志码: A

文章编号: 2095-2163(2025)01-0032-06

### Estimation method of EEG alertness based on multi-feature fusion

ZHU Kui<sup>1</sup>, MIAO Minmin<sup>1,2</sup>, HU Wenjun<sup>1,2</sup>, WANG Shitong<sup>3</sup>

(1 School of Information Engineering, Huzhou University, Huzhou 313000, Zhejiang, China; 2 Zhejiang Province Key Laboratory of Intelligent Management and Application of Modern Agricultural Resources, Huzhou 313000, Zhejiang, China; 3 School of Artificial Intelligence and Computer Science, Jiangnan University, Wuxi 214000, Jiangsu, China)

**Abstract:** Traditional EEG alertness recognition only extracts one type of feature in time domain, frequency domain or nonlinearity, resulting in low accuracy of alertness estimation. Therefore, this paper proposes a multi-feature fusion EEG alertness estimation method. This method first preprocesses the EEG signal, then extracts various features in time domain, frequency domain, and nonlinearity, and further uses the chi-square test for feature selection, and finally inputs the selected features into different classifiers for alertness estimation. The SEED-VIG dataset is used to verify the proposed method. The experimental results show that the EEG alertness estimation method based on multi-feature fusion has a good effect.

**Key words:** EEG signal; alertness; multi-feature fusion; chi-square test

## 0 引言

警觉度亦称持续注意力, 描述人对外界刺激的反应能力以及较长时间内执行同一任务自身注意力的保持程度<sup>[1]</sup>。在某些特殊工作环境中工作人员通常需要保持高度警觉状态, 如高铁驾驶员、飞行员、建筑工人、安保人员等。警觉度的评估方法包括主观评价、生物反应测试、生物化学法、生理信号检测等<sup>[2-3]</sup>。其中生理信号能够精确地对警觉度状态进行评估, 因此在警觉度检测中应用广泛。与脉搏、肌电等生理信号相比, 脑电能够直接反映大脑活动, 在警觉度检测方面受到越来越多学者的关注。

警觉度的研究始于上个世纪 50 年代, 早期研究通常将警觉度分为清醒和嗜睡两种状态, 之后的研究将清醒到嗜睡进一步细分为多个阶段, 将二分类问题转换为多分类问题<sup>[4-5]</sup>。近几年, 已有部分研究团队提出基于机器学习的脑电警觉度估计方法, 文献[6]使用共空间模式(Common Spatial Pattern, CSP)提取多通道脑电特征, 使用基于径向基函数(Radial Basis Function, RBF)的支持向量机(Support Vector Machines, SVM)进行警觉度分类; 文献[7]使用快速傅里叶变换(Fast Fourier Transform, FFT)提取脑电功率谱密度(Power Spectral density, PSD)特征, 使用 SVM 确定警觉度级别; 文献[8]使用小波

**基金项目:** 国家自然科学基金青年科学基金(62101189); 浙江省自然科学基金(LTGC23F010001)。

**作者简介:** 朱 逵(1998—), 男, 硕士研究生, 主要研究方向: 基于脑电的警觉度检测; 胡文军(1977—), 男, 博士, 教授, 主要研究方向: 模式识别。

**通信作者:** 苗敏敏(1989—), 男, 博士, 副教授, 主要研究方向: 脑机接口, 情感计算。Email: 02746@zjhu.edu.cn。

收稿日期: 2023-08-07

变换对原始脑电信号进行预处理,提取标准差、振幅对数和四分位数 3 种特征,使用 SVM 和极限学习机 (Extreme Learning Machine, ELM) 对警觉度进行分类;文献[9]选取最优脑电通道,并提取特征,使用 SVM 和人工神经网络 (Artificial Neural Networks, ANN) 判断其警觉度级别。上述方法均取得了较好的效果,但存在以下缺点:

(1) 提取的特征不完备,只提取了时域、频域或非线性中的某一类特征;

(2) 特征维度大,且存在冗余,影响识别效果。

针对上述两个问题,本文提出了多特征融合的脑电警觉度估计方法,所提方法框架如图 1 所示。

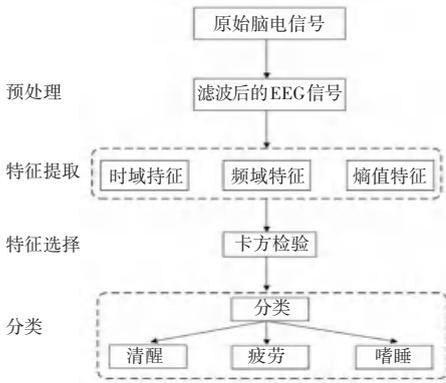


图 1 警觉度估计方法框架

Fig. 1 Framework of alertness estimation method

## 1 方法

### 1.1 脑电预处理

为了减少脑电噪声的干扰,降低计算复杂度,按算法 1 所述步骤进行脑电信号预处理。

#### 算法 1 脑电信号预处理

**Step 1** 将原始脑电数据进行 1-75 Hz 带通滤波处理,并且从 1 000 Hz 降采样到 200 Hz;

**Step 2** 为了获取更有效的脑电信号,使用带阻滤波除去 50/60 Hz 的交流电的干扰;

**Step 3** 将滤波处理之后的脑电信号再次进行降采样处理,由原始的 200 Hz 降采样到 125 Hz。

预处理后,一个样本的采样频率为 125 Hz,即每秒钟脑电信号的采样点数为 125,一个样本采集所需时间为 8 s,设一个样本的所有采样点信号值为  $\{x_i, i = 1, 2, \dots, N\}$ , 所以一个样本的总采样点数则为  $N = 1000$ 。一个受试者采集脑电时间共 118 min, (即  $118 \times 60$  s), 共有 885 ( $118 \times 60 \div 8$ ) 个样本。

### 1.2 脑电特征

脑电信号具有非平稳和非线性特性,为了对脑电信号进行有效分析,本文使用时域分析、频域分析和非线性分析法对脑电信号进行特征提取,共提取 41 种特征,具体见表 1。由于特征集合存在冗余,故进行特征选择。

表 1 脑电特征类型简要说明

Table 1 Brief description of EEG feature types

特征类型	特征名称	特征符号
时域特征	最大值,最小值,平均值,方差,标准差,峭度,均方根,峰值	$X_{\max}, X_{\min}, \mu, \sigma^2, \sigma, \beta, RMS, X_p$
频域特征	直流分量,平均功率谱,功率谱方差,功率谱峭度,功率谱能量	$FDC, MPC, PSV, GSE, PSE$
非线性特征	样本熵,模糊熵,近似熵,谱熵,微分熵(24 频带)	$SE, FE, AE, PS, DE$

#### 1.2.1 特征提取

##### 1) 时域特征提取

脑电的时域特征是描述信号振幅和形态的特征,时域特征值是衡量信号特征的重要指标。文献[10]提取最大值、最小值、平均值、标准差 4 种特征。为了挖掘脑电更丰富的时域信息,本文提取了最大值、最小值、平均值、方差、标准差、峭度、均方根、峰值,其计算公式如下:

$$X_{\max} = \max\{x_1, x_2, \dots, x_N\} \quad (1)$$

$$X_{\min} = \min\{x_1, x_2, \dots, x_N\} \quad (2)$$

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (3)$$

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2 \quad (4)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (5)$$

$$\beta = \frac{1}{N} \sum_{i=1}^N x_i^2 \quad (6)$$

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (7)$$

$$X_p = \max\{|x_1|, |x_2|, \dots, |x_n|\} \quad (8)$$

其中,  $N$  表示采样点数;  $x_i$  表示采样点信号的值;  $\mu$  表示均值。

##### 2) 频域特征提取

脑电的频域特征用于描述信号在不同频率范围内的能量分布和频率成分,频域特征可以补充信号的隐藏模式和频率特性。传统的频谱分析是指利用傅里叶变换进行分析。频谱分析包括振幅频谱和相位频谱,其中振幅频谱是最常用的。功率谱是脑电警觉度识别领域使用最为广泛的特征之一。

文献[11]通过节律波的功率谱平均值和功率谱熵作为驾驶疲劳检测的指标。本文中采用了直流分量、功率谱能量、功率谱熵、功率谱方差、功率谱平均值等5种特征。

### 3) 非线性特征提取

熵的概念来自热力学,是体系混乱程度的度量。在信息论中,熵是衡量时间序列中新信息发生率的非线性动力学参数。

近似熵(Approximate Entropy, *AE*)是一种传统的计算和量化规则性和复杂性的方法,适用于各种相对较短和含噪的时间序列数据<sup>[12]</sup>。

样本熵(Sample Entropy, *SE*)与近似熵一样能进行生理时间序列分析,计算不依赖数据的长度,计算复杂度较低<sup>[13]</sup>。

模糊熵(Fuzzy Entropy, *FE*)是一种新的时间序列规则性度量方法,与 *SE* 和 *AE* 类似, *FE* 是条件概率的负自然对数<sup>[14]</sup>。

谱熵(Spectral Entropy, *SE*)是香农熵公式的归一化版本,适用于脑电信号的功率谱密度的计算。谱熵的估计具有一个独特的特性,即不依赖于信号幅度或频率的绝对值<sup>[15]</sup>。

微分熵(Differential Entropy, *DE*)是香农信息熵在连续变量上的推广形式,公式如下:

$$DE = -\int_a^b p(x) \log(p(x)) dx \quad (9)$$

其中,  $p(x)$  表示连续信息的概率密度函数,  $[a, b]$  表示信息取值的区间,对于一段特定长度的近似服从高斯分布的脑电信号,微分熵公式如下:

$$DE = -\int_a^b \frac{1}{\sqrt{2\pi\sigma_i^2}} e^{-\frac{(x-\mu)^2}{2\sigma_i^2}} \log\left(\frac{1}{\sqrt{2\pi\sigma_i^2}} e^{-\frac{(x-\mu)^2}{2\sigma_i^2}}\right) dx = \frac{1}{2} \log(2\pi e \sigma_i^2) \quad (10)$$

可见,微分熵等于其在特定频段上的能量谱的对数。本文提取了 2~4 Hz, 4~6 Hz, 6~8 Hz, ..., 46~48 Hz, 48~50 Hz 共 24 个频带的微分熵。

#### 1.2.2 特征选择

特征选择是特征工程里的一个重要问题,其目标是寻找最优特征子集。特征选择能剔除不相关或

冗余的特征,从而减少特征个数,提高模型精确度。另一方面,选取出真正相关的特征,协助理解数据产生的过程。本文采用卡方检验方法,从 41 种特征中选取鉴别能力强的特征。

卡方检验是一种用于分类变量之间是否存在关联性的统计方法,通过计算样本的理论值与期望值之间的偏离程度来判断两个分类变量之间是否存在显著的关联性。

## 2 驾驶疲劳检测分析

### 2.1 数据集介绍

数据集来自上海交通大学仿脑计算与机器智能研究中心公开发表的疲劳驾驶数据集 SEED-VIG, 该数据集共有 21 个受试者。使用具有 1 000 Hz 采样频率的神经扫描系统记录每个受试者脑电信号,采集电极位置符合国际 10-20 系统,64 个电极位置分布如图 2 所示,共有 18 个导联,分别是 FT7、FT8、T7、T8、TP7、TP8、CP1、CPZ、CP2、P1、PZ、P2、PO3、POZ、PO4、O1、OZ、O2,其中 CPZ 是参考电极。文献[16]对每个通道的脑电信号提取样本熵、近似熵、模糊熵、谱熵 4 种特征,使用梯度增强决策树对警觉度状态进行分类,其中 TP7 通道效果最好,本文也将基于 TP7 通道进行实验。

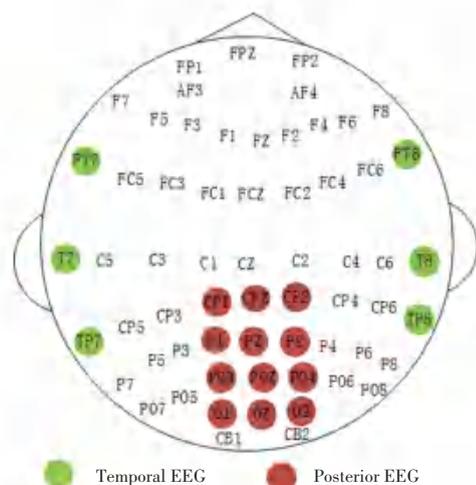


图2 64个电极位置分布

Fig. 2 64 electrode positions

该数据集采用了闭眼百分比作为标签来判断疲劳程度。PERCLOS 指数计算如下:

$$PERCLOS = \frac{blink + clos}{alltime} \quad (11)$$

其中, *alltime* 表示采集一个脑电信号样本所需时间; *blink* 代表 *alltime* 内眨眼时间; *clos* 代表 *alltime*

内闭眼时间。

因此, *PERCLOS* 指数表示受试者在一段时间内眨眼和闭眼时间的占比, 取值范围为  $[0, 1]$ , *PERCLOS* 指数越小, 代表受试者警觉度越高, 疲劳程度越低, 根据两个阈值 (0.35 和 0.7) 将疲劳程度划分为 3 个等级, 分别是清醒、疲劳、嗜睡, 见表 2。

表 2 疲劳程度 *PERCLOS* 指数等级划分

Table 2 Classification of fatigue degree *PERCLOS* index

疲劳程度分类	<i>PERCLOS</i> 指数 (简称 $p$ )
清醒	$0 < p < 0.35$
疲劳	$0.35 < p < 0.7$
嗜睡	$0.7 < p < 1$

### 2.2 分类算法

本文使用随机森林 (Random Forest, RF)、K 最近邻算法 (K-Nearest Neighbor, KNN)、线性判别分析 (Linear Discriminant Analysis, LDA) 和梯度提升决策树 (Gradient Boosting Decision Tree, GBDT) 分类器识别清醒、疲劳和嗜睡 3 种状态。

### 2.3 评价指标

分类算法的性能度量是指对分类算法的泛化性能评估, 是衡量模型泛化性能评价指标, 本文使用准确率 (*Accuracy*)、精确率 (*Precision*)、召回率

(*Recall*) 和 *F1* 分数 (*F1 - score*) 作为评价指标, 公式如下:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (12)$$

$$Precision = \frac{TP}{TP + FP} \quad (13)$$

$$Recall = \frac{TP}{TP + FN} \quad (14)$$

$$F1 - Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (15)$$

其中, *TP* 表示被模型预测为正的正样本; *TN* 表示被模型预测为负的正样本; *FP* 表示被模型预测为正的负样本; *FN* 表示被模型预测为负的负样本。

### 2.4 特征选择结果分析

本文实验均使用一个受试者的数据划分测试集和训练集, 训练集和测试集的比例是 7 : 3。

利用卡方检验进行特征选择, 选取一个最优的特征数  $k$ , 第 21 个受试者不同  $k$  值下 4 种分类器准确率的变化情况如图 3 所示, 当  $k = 15, 20, 36, 15$  时, 4 种分类器的准确率分别达到最高。所选特征的径向直方图如图 4 所示, 图 4 中数字表示频带微分熵, 如 16~18 表示 16~18 Hz 的微分熵。

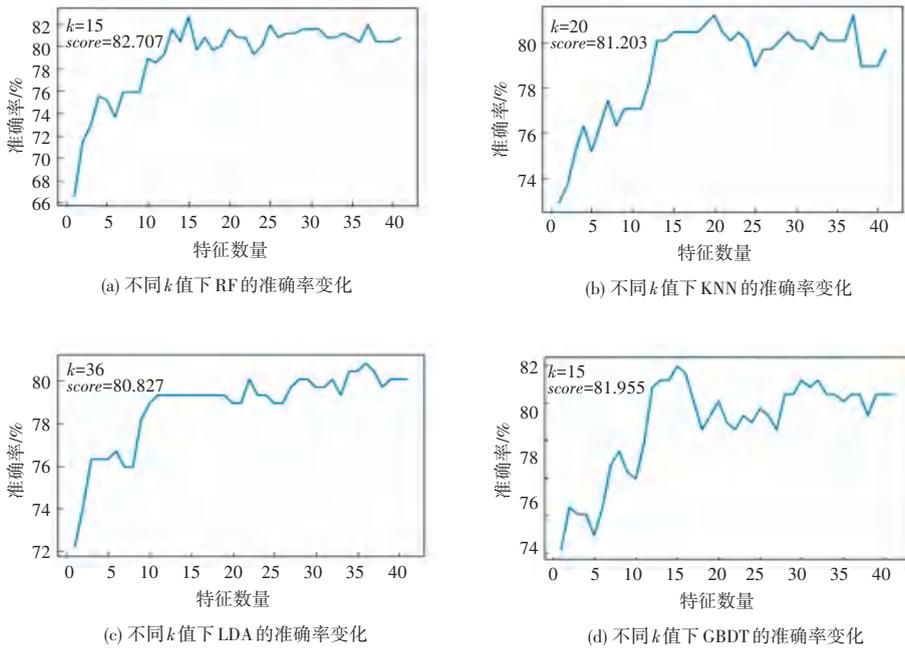


图 3 不同  $k$  值下 4 种分类器准确率的变化情况

Fig. 3 Changes in the accuracy of the four classifiers under different  $k$  values

### 2.5 不同分类算法实验结果分析

21 个受试者 4 种分类器的准确率如图 5 所示。

由图 5 可知 4 种分类器在不同受试者上的准确率差异较小。21 个受试者基于 RF 分类器的混淆矩阵如

图6所示。由图6可知,清醒状态和疲劳状态经常被错分的概率较大。各个性能指标的具体数据见表3,由表3可知RF的准确率最高,比其他3个分类器高0.95%、1.38%、0.78%;RF的F1分数相对GBDT较低;KNN的准确率和F1分数较低;LDA的准确率和F1分数是4种分类器中最低的;GBDT的准确率较高,且GBDT的F1分数最高,比其他分类器高1.73%、2.21%、2.73%,因此GBDT分类器整体效果较好。

为了分析基于脑电警觉度状态识别中特征的重要性,21个受试者特征径向直方图如图7所示,可见平均值特征未被4种分类器选中过;最小值、峭度、最大值、峰值、直流分量、功率谱熵和22~24频带的微分熵特征被选中的次数最少;16~18频带的微分熵特征被选中的次数最多;选中的特征主要分布在提取的非线性特征中,时域与频域特征较少。综上所述,与时域、频域特征相比,非线性特征效果较好。

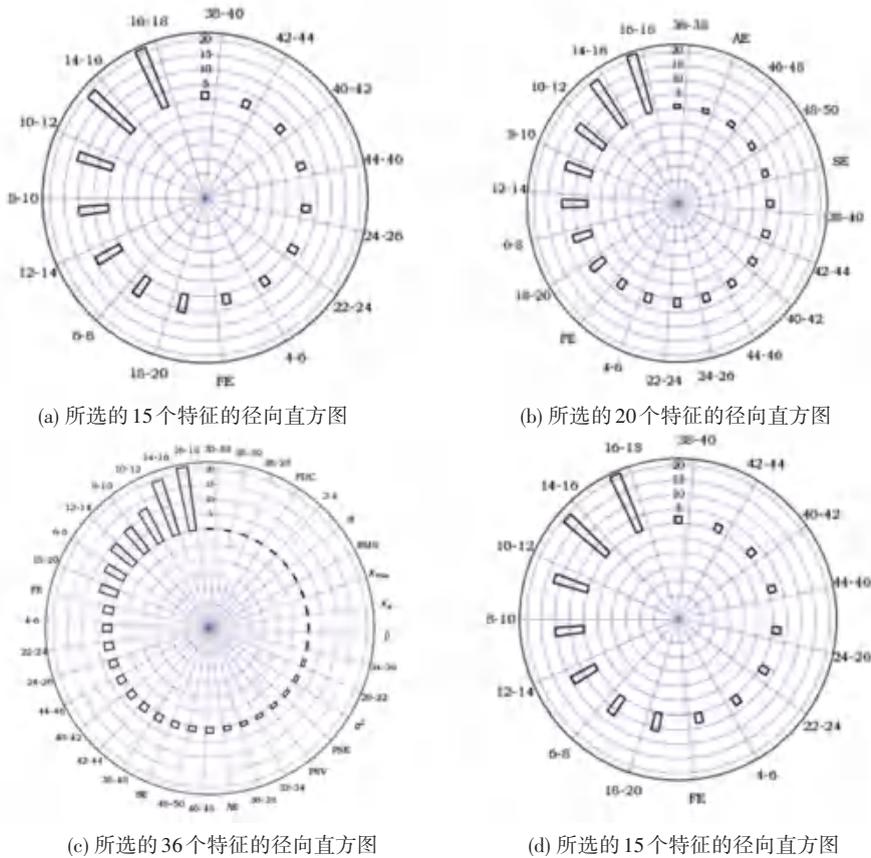


图4 所选特征的径向直方图

Fig. 4 Radial histogram of selected features

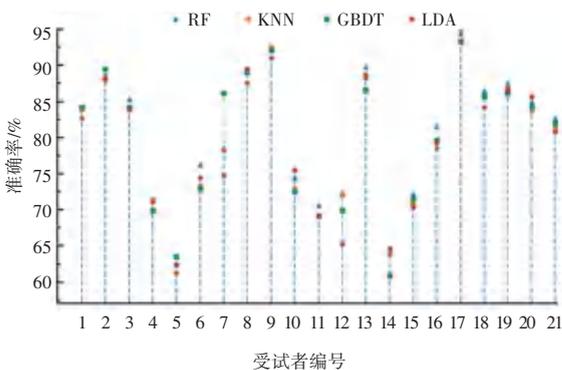


图5 21个受试者4种分类器的准确率

Fig. 5 Accuracy of four classifiers for 21 subjects

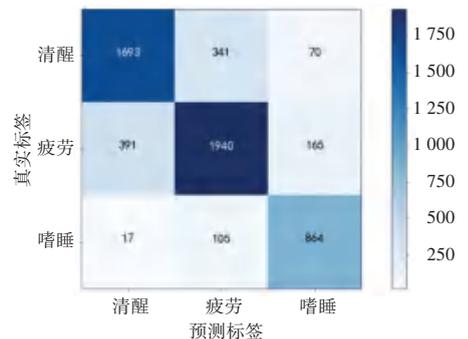


图6 21个受试者随机森林分类器的混淆矩阵图

Fig. 6 Confusion matrix diagram of random forest classifier for 21 subjects

表 3 4 种分类器性能指标

Table 3 Performance indicators of four classifiers %

分类器	准确率	精确率	召回率	F1 分数
RF	80.47	70.18	59.91	60.14
KNN	79.52	69.30	56.76	59.66
LDA	79.09	64.90	59.14	59.14
GBDT	79.69	69.98	60.85	61.87



图 7 21 个受试者特征径向直方图

Fig. 7 Radial histogram of 21 subject characteristics

### 3 结束语

本文提出了多特征融合的脑电警觉度估计方法。首先,对脑电信号进行预处理,随后提取时域、频域和非线性特征;其次,使用卡方检验进行特征选择;最后,实验证实多特征融合的脑电警觉度估计方法具有良好的效果。本文仅使用传统的计算方法提取特征,后期将使用深度学习模型进行脑电特征自动提取。

### 参考文献

[1] SHI L C, JIAO Y Y, LU B L. Differential entropy feature for EEG-based vigilance estimation [C]//Proceedings of 2013 35<sup>th</sup> Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Piscataway, NJ:IEEE, 2013: 6627-6630.

[2] LIU Yuzhong, LIN Zhiqiang, YANG Zhixin, et al. Research progress of work fatigue detection technology [C]//Proceedings of 2020 IEEE 2<sup>nd</sup> International Conference on Civil Aviation Safety and Information Technology (ICCASIT). Piscataway, NJ:IEEE, 2020: 558-560.

[3] ABU F N, ALSHARGIE F, TARIQ U, et al. Improved cognitive vigilance assessment after artifact reduction with wavelet independent component analysis [J]. Sensors, 2022, 22 (8): 3051.

[4] CARSKADON M A. Guidelines for the multiple sleep latency test (MSLT): A standard measure of sleepiness [J]. Sleep, 1986, 9 (4): 519-524.

[5] COLE R J, KRIPKE D F, GRUEN W, et al. Automatic sleep/wake identification from wrist activity [J]. Sleep, 1992, 15(5): 461-469.

[6] 董书琴, 谢宏. 基于 CSP 与 SVM 算法的警觉度脑号分类 [J]. 微型机与应用, 2011, 30(16): 82-84.

[7] ZHANG X, LI J, LIU Y, et al. Design of a fatigue detection system for high-speed trains based on driver vigilance using a wireless wearable EEG [J]. Sensors, 2017, 17(3): 486.

[8] 杨米红, 李会艳, 孙晓舟, 等. 基于脑电信号和极限学习机的警觉度检测研究 [J]. 天津职业技术师范大学学报, 2018, 28(4): 23-27.

[9] UPADHYAY R, MANGLUCK A, REDDY D K, et al. Channel optimization and nonlinear feature extraction for Electroencephalogram signals classification [J]. Computers & Electrical Engineering, 2015, 45: 222-234.

[10] BAJAJ V, TARAN S, KHARE S K, et al. Feature extraction method for classification of alertness and drowsiness states EEG signals [J]. Applied Acoustics, 2020, 163: 107224.

[11] 王利, 艾玲梅, 王四万, 等. 驾驶疲劳脑电信号节律的特征分析 [J]. 生物医学工程学杂志, 2012, 29(4): 629-633.

[12] PINCUS S. Approximate entropy (ApEn) as a complexity measure [J]. Chaos: An Interdisciplinary Journal of Nonlinear Science, 1995, 5(1): 110-117.

[13] RICHMAN J S, LAKE D E, MOORMAN J R. Sample entropy [J]. Methods in Enzymology, 2004, 384: 172-184.

[14] CHEN W, WANG Z, XIE H, et al. Characterization of surface EMG signal based on fuzzy entropy [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2007, 15(2): 266-272.

[15] SRIRAAM N, SHRI T K P, MAHESHWARI U. Recognition of wake-sleep stage 1 multichannel eeg patterns using spectral entropy features for drowsiness detection [J]. Australasian Physical & Engineering Sciences in Medicine, 2016, 39: 797-806.

[16] HU J, MIN J. Automated detection of driver fatigue based on EEG signals using gradient boosting decision tree model [J]. Cognitive Neurodynamics, 2018, 12(4): 431-440.