

基于 GRNN 的可穿戴式脑电仪 EEG 疲劳检测^①

张兆瑞^{②*} 赵群飞^{*} 张朋柱^{③**}

(^{*}上海交通大学自动化系 系统控制与信息处理教育部重点实验室 上海 200240)

(^{**}上海交通大学安泰经济与管理学院 上海 200030)

摘 要 针对单电极可穿戴式脑电仪的脑电波信号 (EEG) 的疲劳状态智能识别,进行了基于广义回归神经网络 (GRNN) 的疲劳状态检测的研究。首先,通过调查问卷调查用户主观疲劳量,结合疲劳检测手环实现 EEG 数据的疲劳等级标记以建立数据集;其次,采用数据清洗等方式实现数据预处理并提取数据的时域特征、频域特征;运用主元分析进行特征降维;然后,建立 GRNN 疲劳识别模型并计算识别准确率;同时以支持向量机 (SVM) 方法作为对比实验检验模型效果;最后,以建立好的 GRNN 模型进行疲劳检测。研究发现,GRNN 模型下 EEG 疲劳状态识别准确率最高为 88.1%,相比 SVM 模型更高,对于 EEG 的疲劳状态的检测具有更好的稳定性和区分度。

关键词 可穿戴式脑电仪,疲劳检测,数据清洗,特征提取,广义回归神经网络 (GRNN),脑电波信号 (EEG)

0 引 言

疲劳是使人处于体虚易发病的状态、造成亚健康的重要原因之一,是一个容易被忽视的健康隐患^[1]。疲劳包含生理疲劳和心理疲劳。身体上的疲劳主要是由于长期的体力、脑力劳动,代谢产生乳酸堆积,造成乏力、工作能力下降和肌肉活动困难;精神上的疲劳多指个人精神上的主观感觉,是指一种缺乏动机与警觉的主观感觉,又称脑力疲劳^[2],会表现出多种症状,如注意力下降,思维不灵敏,工作效率低下等^[3]。影响疲劳程度的客观因素包括工作时长、工作量、工作难度、睡眠时长等^[4]。这些因素都是造成疲劳的直接或间接原因。疲劳包含有感疲劳与无感疲劳,无感疲劳往往在人们没有意识到的情况下发生,容易造成猝死等危害^[5]。

为提供及时的健康状态预警,近年来可穿戴式

健康检测设备快速发展,实现了大规模采集健康信息数据。我国可穿戴智能设备的市场规模从 2010 年的 0.9 亿元飞速发展到 2015 年的 107.9 亿元^[6],结合医疗大数据的发展,为人们的健康状态检测带来了很大的便利。研究表明,可以利用生理信息检测人体的健康状态^[7],其中脑力负荷可以通过使用如心跳、呼吸、瞳仁、肌电图、脑电波信号 (electroencephalogram, EEG) 等生理指标来测量^[8]。从 EEG 可以反映出人体不同脑力负荷下的脑电位表现。智能脑电仪的出现为人体脑力负荷及疲劳状态监控提供了新的发展机会。

国内外利用 EEG 来研究脑疲劳状态已取得一些较好的成果。Charbonnier 等人^[9]指出 EEG 的 α 波与度量精神疲劳外部征兆的眼电指数密切相关,可以准确评估长时间的精神疲劳。Zhao 等人^[10]指出 α 波和 β 波的功率谱密度、事件相关电位 (event-related potentials, ERP)、心电图的近似熵、心率异变

① 国家自然科学基金(91646205)资助项目。
② 男,1993 年生,硕士生;研究方向:模式识别,脑电波分析;E-mail: bestfuture@sjtu.edu.cn
③ 通信作者,E-mail: pzzhang@sjtu.edu.cn
(收稿日期:2018-07-11)

性(heart rate variability, HRV)在长期驾驶前后有显著差异。Madhukar 等人^[11]利用时频分析方法,通过 S 变换发现精神疲劳与 α 波的增加和 α 振幅之和的增加有关。Boostani 等人^[12]利用最小方差波束形成器(minimum variance beamformer, MVB)对 EEG 进行定位和估计,以强度作为特征区分疲劳状态。Cheng 等人^[13]指出 EEG 基本指数 α 、 θ 、比值指数 θ/α 和 $(\alpha + \theta)/\beta$ 对疲劳状态分析均具有统计学意义。

上述文献通过对 EEG 的分析实现了疲劳状态的识别。对于 EEG 的疲劳状态特征分类,支持向量机(support vector machine, SVM)具有较好的效果。林秀晶等人^[14]提出基于 SVM 及递归特征消去(recursive feature elimination, RFE)的自动脑电睡眠分期方法,并改进特征提取算法提高了识别准确率。Xiong 等人^[15]实现了基于 SVM 和复杂度参数的 EEG 的精神疲劳估计,并达到了较高的准确率。Zhao 等人^[16]通过小波包变换提取 EEG 特征向量,利用 KPCA 方法降低特征维数,加快 SVM 的收敛速度,实现了驾驶疲劳较为精准的识别。

采用 SVM 对 EEG 分类可以在疲劳检测上取得一定的效果。但对于噪声较大的情况,及多分类等问题, SVM 仍存在局限性。国内外利用人工神经网络对 EEG 特征分类也取得了一定的成果,邵荔^[17]利用 BP 神经网络及径向基函数(radial basis function, RBF)神经网络实现了脑电的异常波识别。广义回归神经网络(general regression neural network, GRNN)具有更好的分类能力和逼近能力,学习速度更快,适用于噪声较大的样本。Esma 等人^[18]对比了多种人工神经网络用于 EEG 癫痫诊断, GRNN 和 RBF 神经网络取得了较好的分类效果。Aliabadi 等人^[19]指出在使用 EEG 进行癫痫发作诊断中,较之于 RBF 神经网络, GRNN 表现出了更高的准确率。

GRNN 已较好地应用于 EEG 的癫痫诊断,但对疲劳检测的应用较少。本文使用 Neurosky 公司的 mindwave 可穿戴式脑电仪提取测试者的 EEG 信号,依靠 SVM 模型及 GRNN 模型识别人体疲劳状态并区分疲劳等级,研究 EEG 与疲劳的关系,为人们提供及时的预警和监测。

1 EEG 检测概述

EEG 是大脑活动时大量神经元同步发生突触后电位形成的。根据频率变动范围, EEG 可分为 δ 波(1 ~ 3Hz)、 θ 波(4 ~ 7Hz)、 α 波(8 ~ 13Hz)、 β 波(14 ~ 30Hz)、 γ 波(30 ~ 80Hz)^[20]。 α 波度量放松状态, β 波度量清醒、警觉的状态, γ 波常在觉醒并专注于某一事件时出现, θ 波常在人体浅度睡眠或困倦时会出现, δ 波常在成年人体深度睡眠时会出现。

用户的 EEG 信号一般由脑电仪测量。目前较为常见的是多电极的脑电仪传感器,但此类脑电仪佩戴繁琐,不便于携带且佩戴时影响用户正常工作。本文使用一种具有前额电极的便携式可穿戴脑电仪,能够记录脑神经细胞的电生理活动和电位变化,获取 EEG 原始波形^[21]。

研究 EEG 与疲劳的关系首先需要建立 EEG 与疲劳状态的数据集,包括数据采集和对应的疲劳状态。然后对于获取到的 EEG 的初始信号,进行一系列的预处理,特征提取,主成分分析(principal component analysis, PCA)特征降维,并由 SVM 模型及 GRNN 模型两种方法,实现 EEG 的疲劳状态分类。整体的研究框架如图 1 所示。




图 1 整体研究框架图

2 数据集建立

数据集建立包含了从 EEG 信号的采集、传输到疲劳等级标记的过程。

2.1 数据采集和传输

EEG 数据由 mindwave 脑电仪采集。脑电仪可获取脑电波 δ 波、 θ 波、high- α 波、low- α 波、high- β




图 2 EEG 原始波形及节律波波形

2.2 疲劳等级标记

脑力负荷度量指标是度量人体精神疲劳状态的重要依据。评价脑力负荷指标的方法有很多种,包括心率变异性、库柏-哈柏修正法(modified Cooper-Harper method, MCH)、主观负荷评估技术(subjective workload assessment technique, SWAT)、NASA 任务负荷指数量表(NASA task load index, NASA-TLX)等^[22]。

本文 EEG 数据的疲劳状态标记采用了主观方法与客观方法结合的方式对疲劳状态进行评价及标记。分别记录早、午、晚三个时间段相同时长和采样率的受试者 EEG 数据。主观方法为利用受试者多资源调查问卷(multiple resources questionnaire, MRQ),记录各项脑力指标变化状态,并对主观疲劳量(karolinska sleepiness scale, KSS)按照疲劳程度进行等级划分。客观方法为使用疲劳检测手环标记疲劳等级。疲劳等级分为 4 等:不疲劳 0、轻度疲劳 1、中度疲劳 2、重度疲劳 3。受试者包含企业员工和高校学生。员工工作性质分别为互联网与信息通讯类和金融类。高校学生为在读全日制本科生及研究生。数据集建立流程如图 3 所示。

3 数据预处理

脑电仪所获取到的原始数据并不能直接用于机

波、low- β 波、middle- γ 波、low- γ 波、attention 指标、meditation 指标及信号质量 poorSignal 指标。

脑电仪采集到 EEG 后,可以利用蓝牙传输至 Android 系统,用 eegid 软件解析数据后通过 WiFi 传输至 Windows 系统;也可以直接使用蓝牙传输至 Windows 系统,用 ThinkGear API 完成数据的读取和解析。EEG 原始波形及节律波波形如图 2 所示。

器学习的建模,需要经过一系列的预处理及特征提取。




图 3 数据集建立流程图

由于脑电仪的精度问题,采集时产生的跳变及机械噪声等,会很大程度上影响数据质量和分析结果。原始的 EEG 信号存在一定量超出正常取值范围的信号和逻辑上不合理的信号。对此,采用一致性检查的方法进行数据清洗。

一致性检查首先从剔除不良数据开始。当信号质量 poorSignal 指标不为 0 时,脑电仪接触不良,数

据不符合要求,需剔除;当 EEG 变化频率低于仪器采集精度时,会产生一定量相似、重复的信号值,需剔除;当信号峰值异常大时^[23],需剔除。

对于一致性检查所删除的缺失值,利用周围信号均值差分的方法进行估值增补,以保留 EEG 信号连续性及时频特征。以 α 波、 β 波为例,数据清洗前后 EEG 波形如图 4 所示。




图 4 数据预处理

4 数据特征提取

EEG 数据具有特殊性,疲劳样本是非平衡的数据。不疲劳状态 0 与重度疲劳状态 3 的样本相对较少,因此对数据采用随机欠采样方法进行平衡处理。

EEG 波形包含了多种特征,如时域特征、频域特征等^[24]。时域特征可以直接反映信号随时间变化的过程中与时间相关的一些特性,如 EEG 的量级特征、波形能量强度、变化趋势等。

EEG 信号 $g(t)$ 的统计特性时域特征^[25]包含了信号能量、期望值、标准差、一阶差分、二阶差分、一阶差分标准化、二阶差分标准化、中位数 8 项,分别用 $P_g, \mu_g, \sigma_g, \delta_g, \gamma_g, \bar{\delta}_g, \bar{\gamma}_g, m_g$ 表示,共同组成时域特征向量:

$$\mathbf{T}_t = (P_g, \mu_g, \sigma_g, \delta_g, \gamma_g, \bar{\delta}_g, \bar{\gamma}_g, m_g)$$

前 7 项计算公式分别为:

$$\begin{cases} P_g = \frac{1}{T} \sum_{t=1}^T |g(t)|^2 \\ \mu_g = \frac{1}{T} \sum_{t=1}^T g(t) \\ \sigma_g = \sqrt{\frac{1}{T} \sum_{t=1}^T (g(t) - \mu_g)^2} \\ \delta_g = \frac{1}{T} \sum_{t=1}^{T-1} |g(t+1) - g(t)| \\ \gamma_g = \frac{1}{T-2} \sum_{t=1}^{T-2} |g(t+2) - g(t)| \\ \bar{\delta}_g = \frac{\delta_g}{\sigma_g} \\ \bar{\gamma}_g = \frac{\gamma_g}{\sigma_g} \end{cases} \quad (1)$$

其中, t 为时间序列样本点, T 为周期长度。

由于 EEG 各节律波不是单一频率的,而是在某一段频率范围,因此提取其频域特征可以发现信号更多信息。利用离散傅立叶变换的快速算法 (fast Fourier transform, FFT) 对信号进行频域变换,用 $P(f)$ 来表示信号能量与频率的关系。由于每种节律波均在一定频率范围内波动,对于每种节律波所处频段 $[f_a, f_b]$, EEG 信号的频域特征包含了平均

值、最大值、最小值和方差 4 项,分别用字母 μ_p 、 $P_{\max}$ 、 $P_{\min}$ 和 P_v 表示,共同组成频域特征向量:

$$\boldsymbol{T}_f = (\mu_p, P_{\max}, P_{\min}, P_v)$$

计算公式分别为

$$\begin{cases} \mu_p = \frac{1}{f_b - f_a} \sum_{f=f_a}^{f_b} P(f) \\ P_{\max} = \max(P(f)), f \in [f_a, f_b] \\ P_{\min} = \min(P(f)), f \in [f_a, f_b] \\ P_v = \frac{1}{f_b - f_a} \sum_{f=f_a}^{f_b} |P(f) - \mu_p|^2 \end{cases} \quad (3)$$

时域特征与频域特征组合,构成 EEG 的特征向量。

5 SVM 疲劳检测模型

EEG 信号通过特征提取得到了高维特征信息。高维度的特征中噪声及不重要特征过多,PCA 可以有效地选择高维数据中重要的特征,实现特征降维^[26]。

选择 PCA 后的主元变量作为 SVM 模型的输入,采用高斯核函数,用 $\boldsymbol{v}$ 表示特征向量, $\boldsymbol{v}_i$ 表示第 i 个样本的特征向量。高斯核函数为

$$K(\boldsymbol{v}, \boldsymbol{v}_i) = \exp(-\frac{\|\boldsymbol{v} - \boldsymbol{v}_i\|^2}{2\sigma_c^2}) \quad (3)$$

其中 σ_c 为核函数的参数。

以 PCA 后第一主元为横坐标,第二主元为纵坐标,用蓝色、红色、黄色、紫色分别代表疲劳程度为 0、1、2、3 的样本点,分类正确的点用实心 $\bigcirc$ 表示,分类错误的点用 $\times$ 表示,SVM 分类效果如图 5 所示。




图 5 SVM 分类效果

采用混淆矩阵分析模型的分类效果,SVM 模型混淆矩阵如图 6 所示。其中横坐标为预测值,纵坐标为真实值。疲劳状态 0 与 3 区分度比较明显,可以较好地区分不疲劳和重度疲劳状态,疲劳程度 1 和 2 的区分度较差。因此,引入 GRNN 模型可改进疲劳分类效果。

	0	1	2	3
0	89%	7%	3%	1%
1	6%	63%	23%	8%
2	4%	25%	60%	11%
3	1%	2%	6%	91%

图 6 SVM 模型混淆矩阵

6 GRNN 疲劳检测模型

6.1 GRNN 理论与应用

广义回归神经网络是一种非线性回归分析的网络,其模型理论基础为 RBF 网络^[27]。较之于 RBF 网络,GRNN 学习速度更高,且非线性映射能力更强。尤其是在数据集样本较少,或数据噪声较大时,GRNN 可以体现出明显的优势。通常情况下,GRNN 由一层径向基神经网络层和一层线性神经网络层构建。

采用高斯核函数作为传递函数,记高斯函数标准差 σ 为光滑因子。设两个随机变量 x 和 y , $\boldsymbol{X}$ 和 $\boldsymbol{Y}$ 分别为 x 和 y 的一个测试样本值, $\boldsymbol{X}_i$ 和 $\boldsymbol{Y}_i$ 分别是 x 和 y 的第 i 个训练样本值。预测样本 $\hat{\boldsymbol{Y}}(\boldsymbol{X})$ 为:

$$\hat{\boldsymbol{Y}}(\boldsymbol{X}) = \frac{\sum_{i=1}^k \boldsymbol{Y}_i \exp(-\frac{(\boldsymbol{X} - \boldsymbol{X}_i)^T (\boldsymbol{X} - \boldsymbol{X}_i)}{2\sigma^2})}{\sum_{i=1}^k \exp(-\frac{(\boldsymbol{X} - \boldsymbol{X}_i)^T (\boldsymbol{X} - \boldsymbol{X}_i)}{2\sigma^2})} \quad (4)$$

其中 k 为训练样本数^[28]。

EEG 疲劳状态检测的 GRNN 网络结构如图 7 所示。GRNN 共有 4 层:输入层、模式层、加和层和输出层。其输入向量为 $\boldsymbol{X}$,输出向量为 $\hat{\boldsymbol{Y}}(\boldsymbol{X})$ ^[29]。




图7 GRNN 网络结构

输入层:将 EEG 特征向量作为 GRNN 的输入,各神经元直接传递至模式层。神经元数为输入向量维数,传输函数为线性函数。

模式层:模式层各神经元对应不同的样本。神经元数为样本数。传递函数为

$$w_i = \exp\left[-\frac{(\mathbf{X} - \mathbf{X}_i)^T(\mathbf{X} - \mathbf{X}_i)}{2\sigma^2}\right], i = 1, 2, \dots, k \quad (5)$$

加和层:加和层有两类节点,一类节点为模式层神经元输出的算数求和,计算公式为

$$\sum_{i=1}^k \exp\left(-\frac{(\mathbf{X} - \mathbf{X}_i)^T(\mathbf{X} - \mathbf{X}_i)}{2\sigma^2}\right) \quad (6)$$

传递函数为

$$S_D = \sum_{i=1}^N w_i \quad (7)$$

另一类节点为模式层神经元输出的加权求和,计算公式:

$$\sum_{i=1}^k Y_i \exp\left(-\frac{(\mathbf{X} - \mathbf{X}_i)^T(\mathbf{X} - \mathbf{X}_i)}{2\sigma^2}\right) \quad (8)$$

传递函数为

$$S_{Nj} = \sum_{i=1}^N Y_{ij} w_i, j = 1, 2, \dots, m \quad (9)$$

其中, m 为输出向量维数, Y_{ij} 为训练样本输出向量 $\mathbf{Y}_i$ 的第 j 个元素。

输出层:输出层神经元数为输出向量的维数。输出层各神经元 y_j 为

$$y_j = \frac{S_{Nj}}{S_D} \quad j = 1, 2, \dots, m \quad (10)$$

利用 GRNN 进行 EEG 疲劳状态检测的流程图如图 8 所示。将提取的 EEG 特征归一化,并将不同疲劳状态转换成各输出通道。首先,建立初始化 GRNN 模型,设定初始步长、初始精度,代入初始模型中;然后,在训练集中训练 GRNN 模型,求取最优




图8 GRNN 流程图

步长、最优精度,并确定 GRNN 最优参数;最后,分别求取测试集和训练集的分类精度,并利用混淆矩阵进行结果分析。

GRNN 模型下的可穿戴式脑电仪疲劳检测过程如图 9 所示。首先脑电仪采集 EEG 数据,经预处理




图9 疲劳检测流程图

特征提取后,输入至 GRNN 模型进行计算,并将计算结果与预期结果相对比,及时反馈错误结果并将纠错样本扩充至训练集,进而逐步完善模型。

6.2 结果与分析

较之于 SVM 模型,GRNN 网络表现出了更高的准确率。在训练集中,对疲劳状态的分类结果准确率在 99% 以上;在测试集中,准确率最高为 88.1%。绘制测试集准确率对比结果图如图 10 所示。




图 10 测试集准确率

为提升模型的性能,采用 k 折(k 取 5、7、9)交叉验证方法对 GRNN 模型和 SVM 模型分别进行循环交叉验证,记录每次训练过程的准确率。对比交叉验证结果发现,GRNN 模型不仅对 EEG 疲劳状态识别的准确率比 SVM 模型高,并且效果更加稳定。

GRNN 模型混淆矩阵如图 11 所示。对比图 6 的 SVM 模型混淆矩阵,GRNN 模型对于疲劳状态的区分度更高,对于不疲劳状态 0 和重度疲劳状态 3 能够准确地区分。因此 GRNN 模型对于 EEG 疲劳状态分类的准确率、稳定性、区分度更佳。

	0	1	2	3
0	98%	1%	1%	<1%
1	1%	72%	21%	3%
2	<1%	25%	71%	4%
3	<1%	2%	3%	95%

图 11 GRNN 模型混淆矩阵

7 结论

EEG 信号包含的数据信息较大,选择合适的预处理及特征提取方法可以有效获取所需的特征向量,为使用 EEG 识别疲劳程度提供数据支持,构建

EEG 和疲劳程度相匹配的基础模型,即通用模型。在基础模型的基础上,可根据个人特征对模型进行调整,实现更加精准的个性化模型。

GRNN 模型的 EEG 疲劳状态检测相比于 SVM 模型在各方面的属性都有一定的提升,模型训练的速度也有所提升。训练后的 GRNN 模型可以实现对实时采集的用户 EEG 进行疲劳状态检测和反馈。

可穿戴式脑电仪基于 EEG 信号的疲劳检测,结合医疗大数据的发展,为人们的健康状态检测带来了很大的便利。模型可应用于多种场景,如驾驶疲劳检测、高强度脑力劳动者脑力监测等,具有非常广阔的应用前景和巨大的研究价值,是未来脑健康检测的重要手段和依据。

参考文献

[1] 窦颖. 关注亚健康[J]. 中华养生保健,2015(11):4-5

[2] 马进. 健康青年脑力疲劳生理指标和认知功能的实验研究[D]. 西安市:第四军医大学航空航天医学系,2008. 21-25

[3] 吕静. 脑力疲劳状态下注意特征及情绪变化的 ERP 研究[D]. 西安市:第四军医大学航空航天医学系,2008. 10-22

[4] 鲍德国. 疲劳的概念和分类[J]. 全科医学临床与教育,2005,3(3):135-135

[5] 梶本修身. 元気ハツラツでも突然死の危険「隠れ疲労」とは? [EB/OL]. <http://www.yomiuri.co.jp/fukayomi/ichiran/20171201-OYT8T50016>. html; YOMI-URI ONLINE,2017

[6] 姜疆. 医疗大数据:以“提质”促进“增效”[J]. 新经济导刊,2017(11):59-64

[7] 肖元梅. 脑力劳动者脑力负荷评价及其应用研究[D]. 成都:四川大学华西公共卫生学院,2005. 13-17

[8] 崔凯,孙林岩,冯泰文,等. 脑力负荷度量方法的新进展述评[J]. 工业工程,2008,11(5):1-5

[9] Charbonnier S, Roy R N, Bonnet S, et al. EEG index for control operators' mental fatigue monitoring using interactions between brain regions[J]. *Expert Systems with Applications*, 2016, 52(C):91-98

[10] Zhao C, Zhao M, Liu J, et al. Electroencephalogram and electrocardiograph assessment of mental fatigue in a driving simulator [J]. *Accident Analysis and Prevention*, 2012,45(1):83-90

[11] Madhukar B N, Aksharamurali N, Kevin Gonsalves, et al. Measuring a mental fatigue state by analysis of EEG signal using S-transforms [J]. *International Journal of Latest Technology in Engineering, Management & Applied Science (IJLTEMAS) 1st Special Issue on Engineering and*

- Technology*, 2017, 6(5):70-72
- [12] Boostani R, Kouchaki S. Measuring mental fatigue by determining the activity of brain sources[C]. In: International Conference on Intelligent Computational Systems, Dubai, UAE, 2012. 7-8
- [13] Cheng S Y, Hsu H T. Mental fatigue measurement using EEG[J]. *Risk Management Trends Giancarlo Nota. InterchOpen*, 2011: 203-228. doi:10.5772/16376
- [14] 林秀晶, 钱松荣. 基于 SVM_RFE 的脑电波自动睡眠分期算法[J]. *微型电脑应用*, 2015, 31(9):50-52
- [15] Xiong Y J, Zhang R, Zhang C, et al. A novel estimation method of fatigue using EEG based on KPCA-SVM and complexity parameters[J]. *Applied Mechanics & Materials*, 2013, 373-375: 965-969
- [16] Zhao C, Zheng C, Zhao M, et al. Automatic classification of driving mental fatigue with EEG by wavelet packet energy and KPCA-SVM[J]. *International Journal of Innovative Computing Information & Control*, 2011, 7(3): 1157-1168
- [17] 邵荔. 基于小波分析和神经网络的脑电图检测[D]. 西安市:西安工业大学计算机科学与工程学院, 2014. 20-26
- [18] Esma S, Hakan I, Esra S. Employment and comparison of different artificial neural networks for epilepsy diagnosis from EEG signals[J]. *Journal of Medical Systems*, 2012, 36(1):347-362
- [19] Aliabadi R, Keynia F, Abdali M. Epilepsy seizure diagnosis in EEG by artificial neural networks[J]. *Majlesi Journal of Multimedia Processing*, 2013, 2(2):1-5
- [20] 左西年. 脑电波[EB/OL]. <https://baike.baidu.com/item/脑电波:百度百科,2017>
- [21] 李庆之, 董正心, 杜冠宏. 基于 TGAM 模块的疲劳驾驶监测系统[J]. *新型工业化*, 2016, 6(8):22-30
- [22] Rubio S, Díaz E, Martín J, et al. Evaluation of subjective mental workload: A comparison of SWAT, NASA-TLX, and workload profile methods[J]. *Applied Psychology*, 2004, 53(1):61-86
- [23] 周佳苹. 基于可穿戴式脑电仪传感器的疲劳状态研究[D]. 上海:上海交通大学安泰经济管理学院, 2018. 53-57
- [24] Petranonakis P C, Hadjileontiadis L J. Emotion recognition from EEG using higher order crossings[J]. *IEEE Transactions on Information Technology in Biomedicine*, 2010, 14(2):186-197
- [25] Jenke R, Peer A, Buss M. Feature extraction and selection for emotion recognition from EEG[J]. *IEEE Transactions on Affective Computing*, 2017, 5(3):327-339
- [26] Ulfarsson M O, Solo V. Vector, sparse variable PCA[J]. *IEEE Transactions on Signal Processing*, 2011, 59(5):1949-1958
- [27] Specht D F. A general regression neural network[J]. *IEEE Transactions on Neural Networks*, 1991, 2(6):568-576
- [28] 黄金杰, 夏静, 满春涛, 等. 一种参数优化旋转广义回归神经网络模型[J]. *电机与控制学报*, 2009, 13(3):442-447
- [29] 戴虹, 钱晋武, 张震等. GRNN 在肌电预测踝关节运动中的应用[J]. *仪器仪表学报*, 2013, 34(4):845-852

EEG fatigue detection of wearable electroencephalograph based on GRNN

Zhang Zhaorui*, Zhao Qunfei*, Zhang Pengzhu**

(* Laboratory of System Control and Information Processing, Department of Automation, Shanghai Jiaotong University, Shanghai 200240)

(** Antai College of Economics & Management, Shanghai Jiaotong University, Shanghai 200030)

Abstract

A study is carried out based on the fatigue state detection of general regression neural network (GRNN) for intelligent identification of the fatigue state of electroencephalogram (EEG) of a single electrode wearable electroencephalograph. First of all, the data sets are built by using the questionnaire to investigate the Karolinska sleepiness scale that the users feel about and the fatigue level marking EEG data based on fatigue detection bracelet. Then, the data preprocessing is realized by means of datacleaning in order to extract features from both time domain and frequency domain; principal component analysis is used to reduce the dimension of the data; the fatigue recognition model is established by GRNN and the recognition accuracy is calculated; and the support vector machine (SVM) method is used as the comparison to our test model. Finally, the fatigue testing is carried out with the established GRNN model. In conclusion, the GRNN model, whose recognition accuracy under the fatigue state has peaked at 88.1%, gets the better results than the SVM model. It has a better effect on the EEG fatigue detection in the sense of stability and discrimination.

Key words: wearable electroencephalograph, fatigue detection, data cleaning, feature extraction, generalized regression neural network (GRNN), electroencephalogram (EEG)