2024 年 第 24 卷 第 20 期
2024, 24(20):08790-07

科 学 技 术 与 工 程
Science Technology and Engineering

ISSN 1671—1815
CN 11—4688/T

DOI:10.12404/j.issn.1671-1815.2402725
引用格式:李慧, 朱培, 邵荃, 等. 基于决策树模型的管制员工作负荷检测[J]. 科学技术与工程, 2024, 24(20): 8790-8796.
Li Hui, Zhu Pei, Shao Quan, et al. Controller workload detection based on decision tree model[J]. Science Technology and Engineering, 2024, 24(20): 8790-8796.

基于决策树模型的管制员工作负荷检测

李慧[1], 朱培[1*], 邵荃[1], 薛柯[1], 彭晓琳[2]
(1. 南京航空航天大学民航学院, 南京 211106; 2. 广州白云国际机场股份有限公司, 广州 510470)

摘　要　为了验证 gamma 波是否更适用于管制员工作负荷检测,首先设计预实验选取代表性强、区分度大的管制场景场景,在此基础上,设计实验获取管制员在不同工作场景下的脑电(electroencephalogram,EEG)数据及工作负荷数据,并通过 S-W(Shapiro-Wilk)检验验证了选取的实验场景的有效性。随后,提出一系列脑电特征并对根据实际情况对脑电数据划分方法做出改进,并对脑电特与工作负荷的相关性进行分析。结果表明:与 gamma 波相关的特征β+θ+α+γ与工作负荷的相关性最高,可用于管制员的工作负荷检测。最后,选用"留一交叉验证法"建立决策树回归模型对管制员的工作负荷进行检测。检测精度可达 0.979~0.996,证明与 gamma 波相关的功率谱特征可用于管制员工作负荷的检测。

关键词　工作负荷检测; gamma 波; 脑电(EEG); 管制员
中图法分类号　V351;　　**文献标志码**　A

Controller Workload Detection Based on Decision Tree Model

LI Hui[1], ZHU Pei[1*], SHAO Quan[1], XUE Ke[1], PENG Xiao-lin[2]
(1. College of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China;
2. Guangzhou Baiyun International Airport Co., Ltd., Guangzhou 510470, China)

[**Abstract**]　In order to achieve high-precision detection of controller's workload, firstly, pre-experiments was designed to select representative and distinguishable control scene scenarios, based on which, experiments were designed to obtain the (electroencephalogram) EEG data and workload data of controllers in different work scenarios, and the validity of the selected experimental scenarios was verified by the Shapiro-Wilk (S-W) test. Subsequently, a series of EEG features were proposed and their correlation with workload was analysed. The results show that the correlation between the gamma wave-related indexes β+θ+α+γ and workload is the highest, which can be used for the workload detection of controllers. Finally, the "leave-one-out cross-validation method" was used to establish a decision tree regression model to detect the workload of controllers. The detection accuracy is up to 0.979~0.996, demonstrating that the power spectrum features associated with gamma waves can be used for controller workload detection.

[**Keywords**]　workload detection; gamma wave; electroencephalogram (EEG); air traffic controller

近年来,国民用航空业一直处于高速发展的势头,空中交通越来越为繁忙,年平均增长率达 8.5%。2020—2022 年,流量整体呈下跌趋势,但据中商产业研究院分析预测,2023 年后流量将逐年恢复以往水平并持续增加。流量的增加直接使得管制员的工作负荷不断增加,管制难度也与日俱增,从而使得由于管制员的操作失误和人为差错造成的事故呈逐渐上升的趋势[1]。安全是民航运输的底线,安全是民航运输的底线,航空安全是国家安全的重要组成部分,也是民航事业发展的根本保障。在新时代,面对复杂多变的国际形势和日益增长的航空运输需求,必须坚决守住航空安全底线,不断提高民航安全水平,为实现中华民族伟大复兴的中国梦提供有力支撑[2]。

目前运行状况下,由于航空器数量较大,导致航空器的空间位置复杂,管制负荷增大,注意力资源的非合理分配及其他影响航空器运行安全的人为差错占不安全事件的 89.1%[3]。作为空中交通管制的核心,管制员的良好认知过程和适当的工作负荷是保障扇区内航空器运行安全的基础。因此,对管制员的工作负荷展开研究是非常有必要的。目前的工作负荷检测方法主要分为:主观量表法与生理数据检测法。其中,主观量表法有滞后性,而生理数据检测法可反映管制员的实时状态,具备实施评估的基础。在目前

收稿日期: 2024-04-15　　**修订日期**: 2024-05-06
基金项目: 国家自然科学基金委员会-中国民用航空局民航联合研究基金(U2233208)
第一作者: 李慧(2000—),女,汉族,安徽宣城人,硕士研究生。研究方向:交通运输系统优化与仿真、人为因素。E-mail:1109332012@qq.com。
* **通信作者**: 朱培(1989—),男,汉族,河南商丘人,博士,讲师,硕士研究生导师。研究方向:民航安全与应急管理。E-mail:zpei@nuaa.edu.cn。

的检测方法中,脑电信号的精度最高。因此,为了实现精度与实时性两方面的目标,拟采用脑电信号对管制员的工作负荷进行研究。

目前,脑电(electroencephalogram,EEG)信号被证实能够客观反映被试者状态[4]。文献[5]通过对管制员的脑电数据进行分析并得出结论,theta 波随管制员管制负荷及时间增加峰值有明显波动,表明 theta 波能较好地反映出工作负荷变化引起的脑电特征变化。文献[6]采用小波包变换法精准地提取出了脑电信号中 delta(δ)、theta(θ)、alpha(α)和 beta4(β)个频段信号,对飞行员处理飞行过程中出现的异常事件的能力进行客观评估,文献[7]提取出稳态视觉诱发电位信号中的与 delta、theta、alpha 有关的功率谱密度特征,完成对 EEG 信号的分类。文献[8]选取 EEG delta、theta、alpha 和 beta 波的小波包能量和小波包熵构建初始特征空间,研究了作业人员脑力负荷的状态。文献[9]以 theta/(alpha + beta)为脑电特征检测了学生管制员的疲劳状态,结果表明,在 00:00 的疲劳水平显著高于 12:00,且特情反应时间与初始疲劳水平呈线性关系。

尽管目前的研究已在应用脑电设备检测管制员的工作负荷方面取得了很多成果,但仍存在不足之处。首先是频率的方面,由上述分析可知,目前的管制员脑电分析多集中 delta、theta、alpha,beta 波 4 个波段,较少考虑 gamma 波,而 gamma 波一般被认为与高级认知活动有关,理应更适用于空中交通管制员的工作负荷分析。另外,上述对于管制员的脑电研究,实验数据多来自学生管制员,而非有实际工作经验的成熟管制员,这对实验结果的准确性和可应用性也会造成一定的影响。

虽然外国学者在解构管制员的脑电信号等方面已取得很多成果,但由于中国管制员的操作习惯及操作流程与外国存在差异,因此,在对其成果进行应用之前,还需对对其进行适用性分析。还需要注意的是,在对脑电数据进行处理时,传统方法一般是将脑电数据切割为 1 s 或 2 s 的片段,这样在利用分类器分类的时候数据量会变大,因此可靠性也更高。但这种划分方法在管制员的工作负荷分析中存在一些不适用的问题。

据此,首先设计管制模拟实验并邀请具有管制执照的成熟管制员完成实验,获取管制员在不同工作场景下的脑电数据及工作负荷数据。其次,提出与 gamma 波相关的脑电特征,根据实际情况对脑电数据划分方法做出了改进。在此基础上,对管制负荷与该脑电特征的相关性进行分析,证明其对管制情境变化的敏感性,并筛选出相关性最强的脑电特征,建立决策树模型,对管制员的工作负荷进行检测,以保证管制员适当的工作负荷,降低不安全事件发生的概率。

1　实验设计

由图 1 可知,在多种检测方法中,脑电信号不仅可以具备实施评估的基础,精度也是最高的。因此采用管制员的脑电信号对其工作负荷进行分析。

实验部分具体流程如图 2 所示,首先设计预实验选取场景,随后设计实验获取管制员在不同场景下的脑电数据及主观量表数据。最后,验证选取的实验场景是否有效。

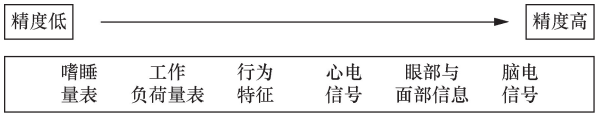

图 1　管制员工作负荷评估方法精度比较

Fig. 1　Comparison of the accuracy of controller workload assessment methods

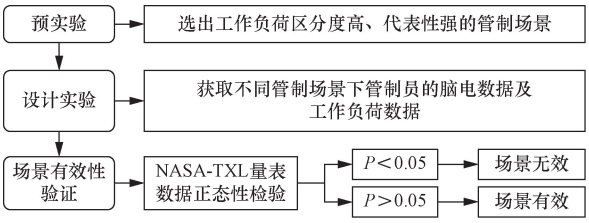

P 为显著性水平

图 2　实验部分流程

Fig. 2　low of the experimental part

1.1　实验被试及设施设备

(1)实验被试。为保证实验数据的准确性,邀请 8 名具有管制执照的管制员作为实验被试完成实验。

(2)参与人员需填写调查问卷。主要收集信息包括性别、年龄、健康状况、视力情况、工作经验等。另需工作人员包括脑电设备配置人员 3 名、脑电信号实时监控人员 1 名、模拟机操作及流程提示人员 1 名、录像及现场摄像人员 1 名。

(3)脑电设备。包括博睿康 NeuSen W 系列无线脑电采集系统(64 导)、导电膏和注射器。如图 3 所示。

(4)管制相关设备。由于实际工作场景中完成实验具有安全隐患,因此选择开展管制模拟实验。管制模拟机由南京航空航天大学提供。

1.2　实验设计

本实验的目的是获取管制员在不同工作场景下的脑电数据及工作负荷数据,因此需设计预实验选取交通繁忙程度不同的实验场景。模拟机中管

制场景多种多样,针对不同的场景,管制员所感知到负荷不同,如何筛选出代表性强,区分度大,管制员之间负荷感知差异小的场景,是拟解决的主要问题之一。

为了设计不同的工作场景,实验开始前,所设计的预实验在管制模拟机上筛选出 4 个区分度较高且具有代表性的练习:负荷较低、负荷较高、负荷过载,特情场景,如表 1 所示。

其中,特情场景指管制员在工作中可能出现的突发情况,本实验中,突发情况为跑道异物入侵。根据预实验结果,使用 SVM(support vector machine)分类器,对已获取数据可分类性进行验证。结果显示,在“场景 4-场景 3-场景 1-场景 2”的顺序下,被试的脑电数据可分性最高,因此,后续实验将按照“场景 4-场景 3-场景 1-场景 2”的顺序进行。

每个场景耗时 30 min,每个被试按照“场景 4-场景 3-场景 1-场景 2”的顺序完成所有练习,场景间隔 5 min,用于填写量表。所有受试者都被要求工作 2 h 以上,在模拟管制的情况下收集脑电数据及 NASA-TXL 主观量表数据。

图 3 脑电信号采集相关设备

Fig. 3 EEG Signal Acquisition Related Equipment

表 1 实验场景

Table 1 Experimental Scenarios

场景	管制练习	负荷	总航班数
场景 1	PX25-12P02	较低	12
场景 2	PX25-17M01	较高	17
场景 3	TWR401-07-1	过载	30
场景 4	PX25-17M01	特情	17

1.3 场景有效性验证

1.3.1 NASA-TXL 量表评分结果

以 NASA-TXL(National Aeronautics and Space Administration task load index)量表评分结果表征被试感知的工作负荷[13],并根据评分结果验证选取场景的有效性。如表 2 所示,实验共采集 8 名被试对特情、过载、负荷较低、负荷较高 4 个场景进行评估。

表 2 NASA-TXL 量表数据

Table 2 Data of NASA-TXL scale

场景	sub1	sub2	sub3	sub4	sub5	sub6	sub7	sub8
4	43.33	37.50	58.33	51.67	45.00	41.67	35.00	40.83
3	49.17	55.00	61.67	71.67	56.67	61.67	53.33	43.33
1	28.33	45.00	48.33	63.33	28.33	36.67	46.67	25.00
2	24.17	49.17	46.67	66.67	51.67	46.67	46.67	40.00

注:sub 为被试。

尽管不同管制员对不同场景的工作负荷感知略有不同,但总体趋势基本一致:管制员在过载场景中感知到的工作负荷最高,在负荷较低场景中感知到的负荷最低。

对于场景 4 和场景 2,不同管制员对其工作量的感知略有不同。这种情况可能是由于工作经验的不同造成的,工作经验较短的管制员对特殊情况场景的反应更为明显。

1.3.2 场景有效性验证

通过处理管制员在不同场景中感知到的工作负荷数据验证选取场景的有效性。首先绘制负荷较低、负荷较高、负荷过载,特情场景这 4 个场景下,管制员 NASA-TXL 主观量表数据的 Q-Q 图(quantile quantile plot),比较管制员工作负荷的观测值与工作负荷预测值(假定正态下的分布)的概率分布,从而检验每个场景下管制员的工作负荷分布是否吻合正态分布规律。

以工作负荷的观测值作为 X 轴,将假定正态时的工作负荷值的分位数作为 Y 轴,作散点图,如图 4 所示。可以看出,散点与直线重合度较高,表明管制员的工作负荷数据较为符合正态分布,可对其进行进一步分析。

由于被试数量较小,因此选择 S-W(Shapiro-Wilk)正态性检验验证场景选取的有效性。该方法是一种用于确定数据集是否服从正态分布的统计方法,适用于小样本量(样本量为 8 ~ 50)检测。使用 PythonScipy 库中的 shapiro 函数执行了 S-W 正态性检验。结果如表 3 所示。4 个场景的 P 均大于 0.05,表明每个场景中受试者的 NASA-TXL 值均符合正态分布。这表明选取的实验场景是有效的。

表 3 正态性检验结果

Table 3 Results of the normality test

变量	中位数	平均数	标准差	偏度	峰度	S-W	P
场景 4	42.500	44.166	7.598	0.931	0.512	0.933	0.547
场景 3	55.835	56.564	8.644	0.281	0.455	0.981	0.969
场景 1	40.835	40.208	13.045	0.546	-0.332	0.925	0.474
场景 2	46.670	46.461	11.842	-0.336	2.357	0.907	0.336

注:P 为显著性水平。

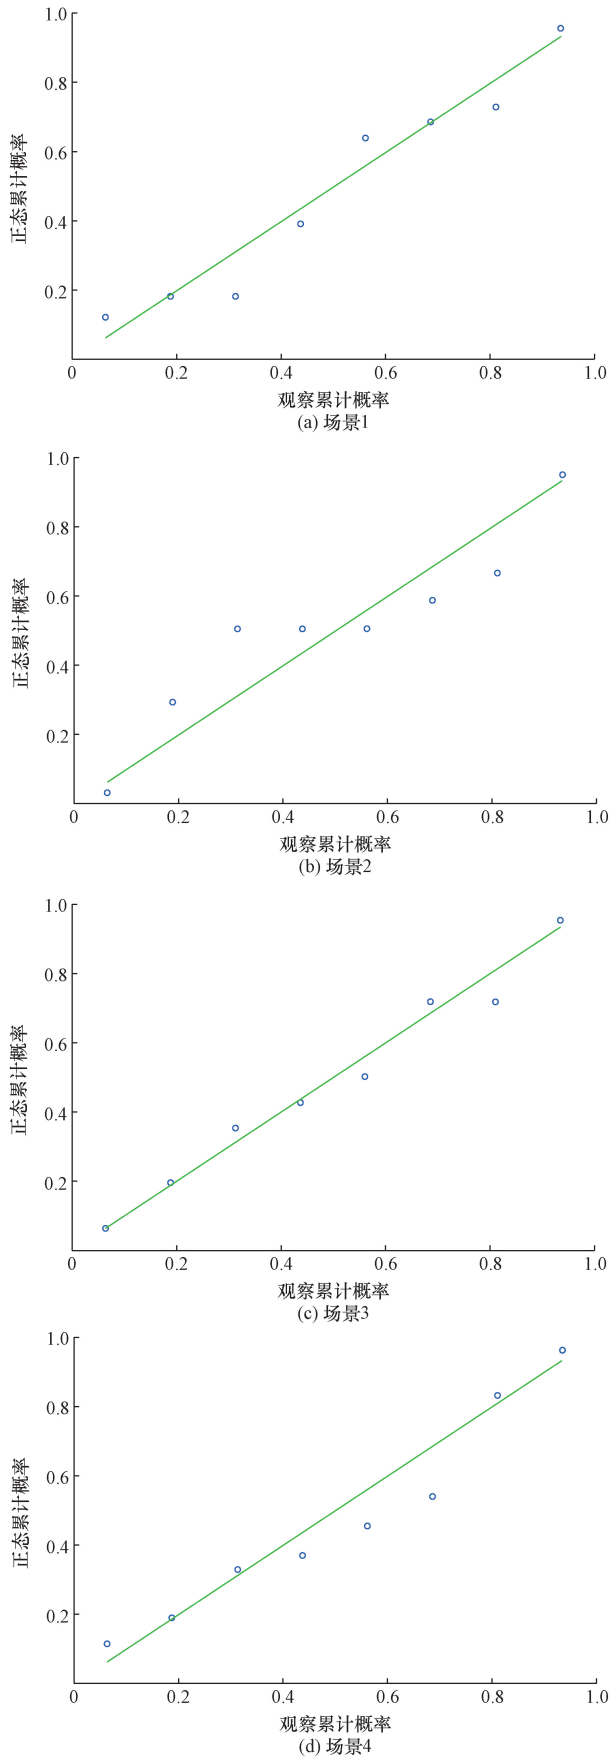

图 4　各场景 Q-Q 图

Fig. 4　Quantile quantile plot of four scenes

2　脑电特征的提出

2.1　特征的提出

旨在利用脑电功率谱特征来区分检测管制员在不同工作负荷下的脑活动变化。为此,需要提取相关的脑电特征目前研究多集中于分析多集中 delta、theta、alpha、beta 波 4 个波段,较少考虑 gamma 波。

因此,为了验证 gamma 波相关的特征是否更适用于工作负荷的检测,首先考虑与 γ 波相关的脑电特征,如 γ/δ、γ/α、γ、γ/(α+β)等,在此基础上,为了形成对比,还考虑常见的传统特征:δ+β+θ+α、θ/β 等[14]。选取的 26 个功率谱特征如表 4 所示。

表 4　脑电特征

Table 4　EEG characteristics

特征 1	δ 绝对能量	特征 14	γ 绝对能量
特征 2	θ 绝对能量	特征 15	δ+β+θ+α+γ
特征 3	α 绝对能量	特征 16	γ/δ
特征 4	β 绝对能量	特征 17	γ/θ
特征 5	δ+β+θ+α	特征 18	γ/α
特征 6	δ/(δ+β+θ+α)	特征 19	γ/β
特征 7	θ/(δ+β+θ+α)	特征 20	γ/(α+β)
特征 8	α/(δ+β+θ+α)	特征 21	γ/(θ+β)
特征 9	β/(δ+β+θ+α)	特征 22	γ/(θ+α)
特征 10	θ/β	特征 23	γ/(θ+β+α)
特征 11	α/β	特征 24	γ/(δ+β+θ+α)
特征 12	(α+θ)/β	特征 25	γ/(δ+β+θ+α+γ)
特征 13	(α+θ)/(α+β)	特征 26	β+θ+α+γ

2.2　计算方法

在分析脑电图数据之前,首先对管制员在不同场景下的脑电数据进行预处理,包括剔除无用电极、重新参照、滤波、独立主成分分析等。

预处理完成后,使用短时傅里叶换来研究管制员在非工作状态、低负荷、高负荷、特殊情况和超负荷状态下的脑活动变化。短时傅里叶变换(short time Fourier transform,STFT)是脑电信号时频分析中常用的分析方法,具体步骤为:①选择窗口长度;②放置窗口;③对窗口将信号分段加权处理,产生一系列数据段;④计算每个加窗数据段的频谱。在 STFT 中,分析窗口越大(数据段长)时,频率分辨率越高,时间分辨率越低;分析窗口越小(数据段短),则时间分辨率越高,与之对应的,频率分辨率会降低。

在应用该方法时,根据实际情况对划分数据的方法做出了改变。传统方法一般是将脑电数据切割为一秒或两秒的片段,这样在利用分类器分类的时候数据量会变大,因此可靠性也更高[15-16]。但这种划分方法在管制员的工作负荷分析中存在一些问题:在管制模拟实验中,每个场景的负荷标签是

确定的,但如果将场景划分为 2 s 的片段,划分后的数据并非全部与该标签吻合。譬如场景 3 对应的标签是负荷较高,但如果将该场景划分为 900 个 2 s 的片段,并非每个片段对应的标签都是负荷较高,在这种划分方法下,数据与标签并不完全对应。

为了解决这一问题,提出不划分时间片段,直接利用短时傅里叶变换求出每个场景对应的特征值。这一处理方式会导致数据量变小,为了使数据量增加,对通道进行分开处理,求出不同场景下,每个被试的 59 通道对应的特征值,这样,在本实验中,每个功率谱特征对应(59 通道 ×8 个被试 ×4 个场景)1 888 组数据。在这种方法下,数据与标签的对应关系非常明确,数据量也会上升。

3 脑电特征的选取

3.1 脑电特征与工作负荷的相关性分析

提出特征后,需选取与工作负荷相关性最强的特征进行进一步分析。为此,对不同脑电特征与工作负荷进行 Pearson 相关性分析。

Pearson 相关系数[17]介于 -1 ~ 1。其中,-1 表示完全的负相关,+1 表示完全的正相关,0 表示没有线性相关。其计算公式为

$$\begin{aligned}\rho_{X,Y} &= \frac{\mathrm{cov}(X,Y)}{\sigma_X\sigma_Y} \\ &= \frac{E[(X-\mu_X)(Y-\mu_Y)]}{\sigma_X\sigma_Y} \\ &= \frac{E(XY)-E(X)E(Y)}{\sqrt{E(X^2)E^2(X)}\ \sqrt{E(Y^2)E^2(Y)}}\end{aligned} \tag{1}$$

式(1)中:X 为脑电特征值;$E(X)$ 为 X 的均值;Y 为对应的工作负荷的值;σ_X、σ_Y 为脑电特征值与工作负荷标准差;μ_X、μ_Y 为对应的均值;$\mathrm{cov}(X,Y)$ 为脑电特征值与工作负荷值之间的协方差。

虽然皮尔森相关系数的计算公式相较于欧几里得距离计算公式要复杂一些,但在数据不是很规范的时候,皮尔森相关系数会倾向于给出更好的结果。

3.2 分析结果

对 26 个特征与工作负荷的进行 Pearson 相关性分析,结果如图 5 所示。

由图 5 可知,所有特征都与工作负荷存在相关关系。且在所有特征中,特征 6:δ/(δ+β+θ+α)、特征 7:θ/(δ+β+θ+α)、特征 17:γ/θ、特征 18:γ/α、特征 21:γ/(θ+β)、特征 22:γ/(θ+α)、特征 23:γ/(θ+β+α)、特征 25:γ/(δ+β+θ+α+γ);特征 26:β+θ+α+γ 与工作负荷展现出强相关关系。

	被试1	被试2	被试3	被试4	被试5	被试6	被试7	被试8	均值
特征1	0.404 0	0.867 0	0.470 7	0.065 0	0.315 7	0.496 1	0.766 5	0.766 5	0.518 9
特征2	0.460 2	0.908 1	0.432 9	0.116 5	0.434 1	0.631 9	0.725 9	0.725 9	0.554 5
特征3	0.465 9	0.883 0	0.412 5	0.214 4	0.490 4	0.551 1	0.627 6	0.627 6	0.534 1
特征4	0.673 7	0.844 4	0.365 5	0.389 7	0.351 2	0.352 9	0.566 5	0.566 5	0.513 8
特征5	0.510 7	0.892 6	0.416 1	0.191 6	0.487 1	0.549 0	0.675 7	0.675 7	0.549 8
特征6	0.690 1	0.941 2	0.481 7	0.165 2	0.425 3	0.491 2	0.812 6	0.812 6	0.602 5
特征7	0.528 9	0.958 2	0.483 7	0.309 0	0.438 2	0.487 1	0.970 6	0.970 6	0.643 3
特征8	0.447 1	0.936 6	0.493 7	0.138 7	0.452 0	0.455 7	0.771 9	0.771 9	0.558 4
特征9	0.840 3	0.889 1	0.425 9	0.419 5	0.366 9	0.273 2	0.747 2	0.747 2	0.588 6
特征10	0.887 7	0.452 6	0.219 3	0.626 7	0.442 6	0.256 3	0.548 1	0.548 1	0.497 7
特征11	0.866 9	0.455 4	0.230 7	0.707 1	0.502 5	0.440 0	0.559 6	0.559 6	0.540 3
特征12	0.877 8	0.463 1	0.222 2	0.644 7	0.474 6	0.361 1	0.552 2	0.552 2	0.518 5
特征13	0.918 8	0.551 9	0.171 6	0.614 6	0.481 6	0.211 2	0.753 1	0.753 1	0.557 0
特征14	0.658 7	0.709 8	0.286 3	0.647 9	0.257 4	0.475 4	0.495 6	0.495 6	0.503 3
特征15	0.543 7	0.880 7	0.396 5	0.214 8	0.397 5	0.559 6	0.651 1	0.651 1	0.540 3
特征16	0.709 5	0.754 8	0.310 9	0.634 7	0.273 3	0.455 8	0.610 7	0.610 7	0.545 1
特征17	0.766 9	0.878 9	0.401 3	0.442 3	0.349 9	0.492 2	0.832 9	0.832 9	0.624 7
特征18	0.736 2	0.846 3	0.319 6	0.576 0	0.447 3	0.455 9	0.926 1	0.926 1	0.655 4
特征19	0.774 2	0.494 2	0.322 7	0.685 6	0.370 5	0.378 0	0.663 0	0.663 0	0.543 9
特征20	0.763 7	0.583 2	0.205 7	0.674 5	0.350 5	0.436 4	0.787 5	0.787 5	0.573 6
特征21	0.769 8	0.856 0	0.385 5	0.503 8	0.449 0	0.469 0	0.907 0	0.907 0	0.655 9
特征22	0.758 6	0.894 5	0.415 6	0.420 9	0.329 0	0.484 3	0.871 7	0.871 7	0.630 8
特征23	0.765 4	0.855 7	0.372 8	0.517 2	0.479 9	0.466 6	0.913 4	0.913 4	0.660 6
特征24	0.718 8	0.831 9	0.381 3	0.548 4	0.305 5	0.478 2	0.765 4	0.765 4	0.599 4
特征25	0.724 9	0.848 2	0.391 4	0.535 5	0.960 0	0.475 1	0.810 3	0.810 3	0.611 5
特征26	0.840 3	0.889 1	0.625 9	0.879 5	0.696 9	0.673 2	0.747 2	0.747 2	0.762 4

图 5 相关性分析结果

Fig. 5 Correlation analysis results

在这 9 个特征中,除特征 26 外,都出现了个别被试相关性较低的情况,这是由个体之间的差异性造成的。其中,特征 6 和特征 7 不适用于被试 4 的工作负荷检测;特征 17 和特征 22 不适用于被试 5 的工作负荷检测;特征 18、21 和 23 不适用于被试 3 的工作负荷检测。

而特征 26 $\beta+\theta+\alpha+\gamma$,与所有被试的工作负荷都表现出强相关性,因此,将使用各被试在特征 $\beta+\theta+\alpha+\gamma$ 下的相关数据建立管制员工作负荷检测模型。

4　管制员工作负荷检测模型

4.1　模型建立

由于研究设计的样本量不大,采用决策树模型对管制员的工作负荷进行检测,为充分利用实验数据,同时过拟合现象,采取"留一交叉验证法"建立模型。建模步骤如下。

步骤 1　整理与管制员工作负荷相关的数据,包括输入特征 $\beta+\theta+\alpha+\gamma$ X 和目标变量 Y(工作负荷)。

步骤 2　划分数据。将数据集划分为训练集(占总样本的 70%)和测试集(占总样本的 30%)。训练集用于构建模型,测试集用于评估模型性能。将原始数据集中的一个样本作为测试集,其余的样本作为训练集。

步骤 3　模型构建。使用训练集数据,训练决策树回归模型。每次选取 1 名受试者作为测试样本,其余受试者作为训练样本,依次循环直到所有样本均被测试 1 次。

步骤 4　参数设置。为了提高模型的准确性,采用网格搜索法寻找最优参数组合。

步骤 5　评估模型的性能。

4.2　模型结果

在建立模型后,将 8 个被试的数据依次输入模型,结果如图 6 所示。可以看出,被试 4 的准确率最高,可达 0.996,被试 5 的准确率最低,但也有 0.979。被试的精度(P_{recision})为 0.98±0.02、召回率(R_{ecall})为 0.959~1、F_1 分数($F_{1\text{-score}}$)最低为 0.969。除被试 7 外,ROC AUC(receiver operating characteristic curvearea under curve)最低为 0.95,但被试 7 的 ROC AUC 并不理想,如图 6 中蓝色虚线部分所示,该值仅有 0.9。结果表明,所建立的管制员工作负荷模型的各项评价特征符合预期,可用于管制员工作负荷的检测。

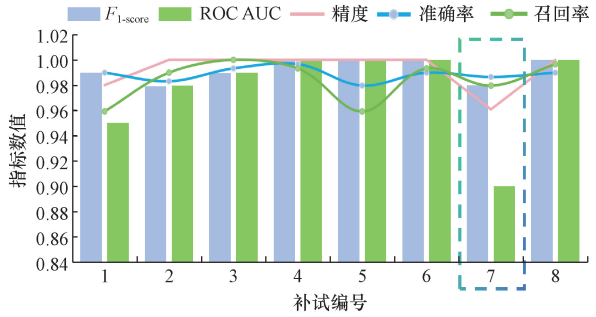

图 6　模型结果

Fig. 6　Model results

5　结论

为了验证 gamma 波是否更适用于管制员工作负荷的检测,首先设计预实验选取代表性强,区分度大的 4 个管制模拟场景:负荷较低、负荷较高、负荷过载,特情,随后,通过实验获取管制员在不同工作场景下的脑电数据及工作负荷数据,并通过 S-W 检验验证了选取的实验场景的有效性。在此基础上,提出一系列脑电特征并对其与工作负荷的相关性进行分析,结果显示,与 gamma 波相关的特征 $\beta+\theta+\alpha+\gamma$与工作负荷的相关性最高,可用于管制员的工作负荷检测。最后,建立决策树回归模型对管制员的工作负荷进行检测,检测精度可达 0.979~0.996,证明与 gamma 波相关的功率谱特征可用于管制员工作负荷的检测。

参　考　文　献

[1] 何黎敏. 空中交通管制员职业倦怠与人因失误的关系研究[J]. 黑龙江科技信息, 2015(14): 282.
He Limin. Research on the relationship between air traffic controller burnout and human factor error[J]. Heilongjiang Science and Technology Information, 2015(14): 282.

[2] 韩凯. 坚决守住航空安全底线 不断提高民航安全水平[N]. 中国民航报社, 2024-02-08(T01).
Han Kai. Resolutely adhere to the bottom line of aviation safety and continuously improve the level of civil aviation safety[N]. Civil Aviation News of China, 2024-02-08(T01).

[3] 张超. 空中交通管制中的人为因素及管控研究[D]. 昆明:云南大学, 2019.
Zhang Chao. Research on human factors and control in air traffic control[D]. Kunming: Yunnan University, 2019.

[4] 戚春华, 刘昱忻, 李航天, 等. 基于驾驶员警觉度的交通标志适宜信息量研究[J]. 科学技术与工程, 2021, 21(34): 14829-14835.
Qi Chunhua, Liu Yuxin, Li Hangtian, et al. Research on the information volume of suitable traffic signs at intersections based on driver's alertness[J]. Science Technology and Engineering, 2021, 21(34): 14829-14835.

[5] Shou G, Ding L. Frontal theta EEG dynamics in a real-world air traffic control task[C]//Annual International Conference of the IEEE Engineering in Medicine and Biology Society. New York: IEEE, 2013: 5594-5597.

[6] 崔志翔, 陈大伟, 吴东苏, 等. 飞行员异常事件处理能力的脑电评估方法[J]. 科学技术与工程, 2022, 22(30):

13562-13568.
Cui Zhixiang, Chen Dawei, Wu Dongsu, et al. EEG-based evaluation method for pilots abnormal event handling competency[J]. Science Technology and Engineering, 2022, 22(30): 13562-13568.

[7] 张学军, 杨京儒. 基于 PSD 特征的 FBCCA 脑电信号识别方法[J]. 科学技术与工程, 2024, 24(4): 1411-1417.
Zhang Xuejun, Yang Jingru. FBCCA SSVEP EEG signal recognition method based on PSD[J]. Science Technology and Engineering, 2024, 24(4): 1411-1417.

[8] 聂俊峰, 刘维平, 金毅, 等. 基于脑电的乘员信息处理作业脑力负荷状态识别模型[J]. 科学技术与工程, 2017, 17(20): 35-41.
Nie Junfeng, Liu Weiping, Jin Yi, et al. Recognition method of information processing mental workload based on EEG[J]. Science Technology and Engineering, 2017, 17(20): 35-41.

[9] 王莉莉, 陈凤兰. 基于脑电的管制员认知行为与疲劳的关系研究[J]. 中国安全科学学报, 2018, 28(7): 1-6.
Wang Lili, Chen Fenglan. An EEG-based study of the relationship between controllers' cognitive behaviour and fatigue[J]. Chinese Journal of Safety Science, 2018, 28(7): 1-6.

[10] Krish V K, Dasaei D, Ding L. EEG correlates of fluctuation in cognitive performance in an air traffic control task: DOT/FAA/AM-14/12[R]. Washington D. C.: Office of Aerospace Medicine, Federal Aviation Administration, 2014.

[11] Majd F, Majld M, Rashid H, et al. Analysis of the mental workload of city traffic control operators while monitoring traffic density: a field study[J]. International Journal of Industrial Ergonomics, 2016, 4: 170-177.

[12] Nabeel A, Sadio A. Classification of EEG signals using adaptive time frequency distributions[J]. Metrology and Measurement Systems, 2016, 23(2): 75-79.

[13] Riccio A. Workload measurement in a communication application operated through a P300-based brain-computer interface[J]. Journal of Neural Engineering, 2011, 8(2): 25-28.

[14] 张朋, 周前祥, 于洪强, 等. 基于 EEG 信号特征的脑力疲劳快速检测方法[J]. 北京航空航天大学学报, 2023, 49(1): 145-154.
Zhang Peng, Zhou Qianxiang, Yu Hongqiang, et al. A rapid brain fatigue detection method based on EEG signal characteristics[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(1): 145-154.

[15] Lin S Y, Wu Y T, Mao W C. Signal analysis of patients with obstructive sleep apnea syndrome (OSAS) using power spectrum and fuzzy entropy[C]//International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD). Guilin: IEEE, 2017: 677-681.

[16] Zhang C, Wang H, Fu R R. Automated detection of driver fatigue based on entropy and complexity measures[J]. IEEE Transactions on Intelligent Transportation Systems, 2014, 15(1): 168-177.

[17] Xia Z, Song Y X, Ma J, et al. Research on the Pearson correlation coefficient evaluation method of analog signal in the process of unit peak load regulation[C]//13th IEEE International Conference on Electronic Measurement & Instruments (ICEMI). Yangzhou: IEEE, 2017: 522-527.