

<http://bhxb.buaa.edu.cn> [jbuaa@buaa.edu.cn](mailto:jbuaa@buaa.edu.cn)

DOI: 10.13700/j.bh.1001-5965.2024.0057

# 基于面部特征的管制员疲劳判别算法

王莉莉\*, 殷硕峰, 潘越

(中国民航大学天津市空管运行规划与安全技术重点实验室, 天津 300300)

**摘要:** 针对现有通过管制员面部信息监测疲劳, 极少融合管制真实场景、算法鲁棒性低等特点, 提出一种考虑管制员工作特性的疲劳实时判别算法。采用 Attention Mesh 算法获取面部 468 点的三维坐标信息, 并使用特征匹配法逐样本对眼部与嘴部纵横比阈值进行标定; 引入管制员在岗时间、实时陆空通话负荷及疲劳事件发生次数 3 个指标, 将三者通过指数衰减函数动态映射至疲劳监测时间窗口, 并通过计算动态衰减时间窗内眨眼频次占比, 得出疲劳趋势指标。对某管制单位管制室 30 位成熟放单管制员班后管制测试的脑电与面部视频数据进行处理, 并对通过面部数据得到的疲劳指标  $F_o$  与脑电疲劳指标  $F_e$  进行时间维度上的相关性分析, 结果表明: 在 30 个被试样本的双变量交叉相关性分析结果中, Pearson 相关性系数整体介于 0.462~0.785 之间, Sig. 双尾显著性检验均位于 0.01 级别, 相关性显著, 验证了所提算法的有效性 with 可靠性。

**关键词:** 管制员; 疲劳判别; 人脸关键点检测; 陆空通话负荷; 脑电信号

**中图分类号:** V355.1; TP391.41

**文献标志码:** A **文章编号:** 1001-5965(2026)04-0986-09

随着经济的持续发展和人们出行需求的不断提高, 民航领域也迎来了前所未有的发展机遇。管制员作为空中交通管制工作的重要角色, 肩负着保障航空安全和航班有效管理的重任。然而, 随着航班数量的增加, 管制员所面临的工作负荷也相应增加。因此, 如何对管制员的疲劳状态进行准确的判定和预警, 对于预防空中交通管制不安全事件的发生具有重要意义。

目前, 通过面部特征进行疲劳状态监测的研究中, 驾驶员疲劳领域相关研究成果颇多。Li 等<sup>[1]</sup> 提出基于改进的 YOLOv3-tiny 卷积神经网络 (convolutional neural network, CNN) 和 Dlib 库的驾驶员疲劳检测方法, 在复杂背景下获取驾驶员面部区域, 通过评估驾驶员的眼部和嘴部状态, 计算闭眼时间、眨眼频率和打哈欠次数来判断驾驶员的疲劳状态, 并通过模拟驾驶实验验证该方法的准确度约为

95.1%; Ji 等<sup>[2]</sup> 采用多任务级联卷积神经网络 (multi-task cascaded convolutional neural network, MTCNN) 实现人脸和特征点定位, 通过 CNN 提取眼部疲劳特征和嘴部疲劳特征, 建立多指标融合疲劳判定模型, 判断驾驶员疲劳状态。在管制员疲劳研究领域, 通过面部特征进行疲劳监测普遍借鉴自驾驶员疲劳监测算法。汪磊等<sup>[3]</sup> 基于 OpenCV 开源计算机视觉库, 结合图像二值化和模块匹配等技术, 对管制员疲劳状况进行识别, 取得了不错的检测效果; 史增鹏<sup>[4]</sup> 采用 Adaboost 算法实现了对人脸的快速定位, 并基于统计学习的人脸检测算法, 进一步确定眼睛和嘴巴的矩形区域, 并进行状态识别和预测。以上研究在进行面部关键点定位时普遍使用二维坐标信息, 忽略了部分空间特征, 同时在疲劳判定过程中, 极少融入管制员工作场景的特点。

在基于脑电 (electroencephalogram, EEG) 信号

收稿日期: 2024-01-24; 录用日期: 2024-08-19; 网络出版时间: 2024-08-26 08:57

网络出版地址: [link.cnki.net/urlid/11.2625.V.20240823.1416.001](http://link.cnki.net/urlid/11.2625.V.20240823.1416.001)

基金项目: 国家自然科学基金委员会与中国民用航空局联合资助项目 (U1633124)

\* 通信作者. E-mail: [llwang317@163.com](mailto:llwang317@163.com)

**引用格式:** 王莉莉, 殷硕峰, 潘越. 基于面部特征的管制员疲劳判别算法 [J]. 北京航空航天大学学报, 2026, 52 (4): 986-994.

WANG L L, YIN S F, PAN Y. Controller fatigue discrimination algorithm based on facial features [J]. Journal of Beijing University of Aeronautics and Astronautics, 2026, 52 (4): 986-994 (in Chinese).

进行管制员疲劳监测的领域中, 国外已取得了丰富的成果。Lal 等<sup>[5]</sup>提出 EEG 是衡量疲劳程度的最合理指标之一, 其能够有效捕捉大脑活动的变化, 从而反映个体的疲劳状态。Bernhardt 等<sup>[6]</sup>在研究管制学生模拟机任务中的 EEG 信号时, 发现随着管制架次的增加和注意力分散任务的增多, 个体的感知能力和反应速度会有所下降。Aricò 等<sup>[7]</sup>通过设计实验, 测试 12 名在校管制学员, 建立 EEG 模型, 基于大量 EEG 数据进行分析, 通过识别特定的脑电波特征, 准确衡量个体的疲劳状态。综上所述, EEG 能够直观且准确地反映个体的疲劳趋势, 但其对测试环境和成本的要求较高。鉴于 EEG 在疲劳监测领域中被广泛认为是“金标准”, 本文提出了一项研究方案, 旨在利用 EEG 数据对基于面部特征的疲劳监测算法进行有效性检验。

本文针对现有通过管制员面部信息监测疲劳, 极少融合管制真实场景、算法鲁棒性低等特点, 提出一种融合管制工作相关特性的疲劳实时判别算法。首先, 在提出的轻量化 VIT 人脸检测算法<sup>[8]</sup>基础上, 采用精度与鲁棒性更高的 Attention Mesh<sup>[9]</sup>三维人脸关键点检测算法, 获取面部 468 点的三维坐标信息, 计算眼睑与嘴部的三维欧几里得距离, 并在重构纵横比函数后, 采用特征匹配法逐样本对其眼部与嘴部纵横比阈值进行标定, 以缓解由个体差异引起的测试误差; 其次, 引入管制员在岗时间、实时陆空通话负荷及疲劳事件发生次数 3 个指标, 将三者通过指数衰减函数动态映射至疲劳监测时间窗口, 并通过计算动态衰减时间窗内眨眼频次占比得出疲劳趋势; 最后, 通过设计相关实验, 采集并处理了某管制单位管制室 30 位成熟放单管制员的 EEG 与面部视频数据, 将通过面部数据得到的疲劳指标  $F_s$  与 EEG 疲劳指标  $F_e$ , 利用 SPSS 进行相关性分析, 验证本文算法的有效性。

### 1 人脸关键点检测

在以往的研究工作中, Dlib 库和 OpenFace 等常被用于面部 68 点定位。然而, 这些方法在处理非正面人脸图像时存在一些局限性。例如, 当角度倾斜或面部表情过于复杂时, Dlib 库的内置算法检测效果可能会受到影响。此外, Dlib 库和 OpenFace 在应对遮挡方面的鲁棒性较弱。针对以上问题, 本文提出使用 Google 基于 Face Mesh<sup>[10]</sup>改进的 Attention Mesh 算法, 该算法能够检测面部 468 个关键点, 相较于 68 点定位方法更加精细。这种细粒度的检测不仅在复杂的角度和表情下依然保持较高的检测精度, 还能提供更丰富的面部特征信息, 从而显著

提升下游任务效果。其中, 算法基于 RGB 图像(不含深度信息)估计出三维网格顶点位置, 网格拓扑结构由 468 点构成, 如图 1 所示。

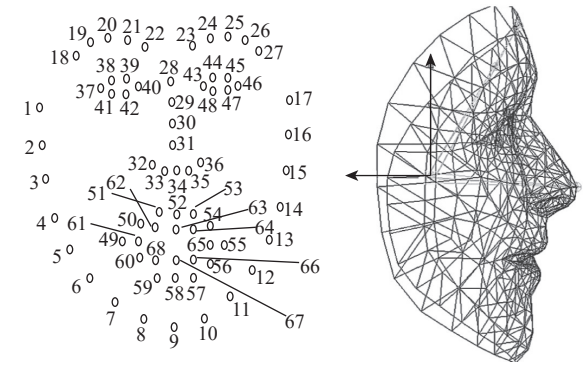


图 1 人脸二维 68 点与三维 468 点对比示意图  
Fig. 1 Comparison of 2D 68-point and 3D 468-point of face

#### 1.1 模型推理流程

在 Face Mesh 算法中, 单帧图像通过人脸检测器进行二分类, 并回归出 Boundingbox 信息与 5 个标记点位置(包括双眼、双耳与鼻尖), 这些标记点用于旋转面部矩形框并使人脸双眼之间的连线平行于图像  $x$  轴, 将处理后的图像剪裁缩放至  $128 \times 128$  后输入至关键点检测模型, 该模型的输出为三维坐标向量与人脸置信度。将三维坐标映射回原始图像坐标系。考虑到处理每一帧图像都会调用一次人脸检测器, 会对处理实时视频流效率带来较大影响。因此, 该算法在初始帧使用人脸检测器获取人脸位置, 后续帧通过前一帧的预测结果进行人脸位置跟踪, 无需重复调用人脸检测器, 直至人脸标志预测的概率低于适当的阈值后, 则会重新调用人脸检测器<sup>[10]</sup>。该算法可以避免人脸检测器的冗余使用, 更好地降低计算量, 提升单帧图像的处理速度。

#### 1.2 Face Mesh 模型结构与模型训练

在模型结构上, 首先使用残差神经网络在早期进行大幅度的下采样, 以此减小模型体量, 提升计算速度。与此同时, 快速到达网络深层, 便于提取眼睛与嘴部的分类语义信息。由于视图存在轻微的仿射变换、头部姿势变化、光线变化及各种相机传感器噪声的影响<sup>[11]</sup>, 这些情况会引发肉眼可见的波动, 或者在时间上出现偏差。为处理这类时序震荡问题, 该算法采用一种特殊的低通滤波器。这种滤波器保持了固定的滚动窗口, 该窗口包含了几个时间戳样本, 用于进行速度估计; 而且该滤波器能够根据人脸的大小进行自我调整, 以适应视频流中人脸比例的变化; 能够有效平抑各种因素引起的波动和偏差, 提高了整体任务的准确度和鲁棒性。

该模型在训练层面采用了先进的自助法与增量学习策略。在训练出初始模型后, 通过初始模型

预测关键点信息并进行人工微调,将微调后的数据再次训练新的模型,如此不断进行迭代精调。其中,初始模型的数据来源于三维合成渲染模型与人工标注。

### 1.3 Attention Mesh 算法优势

相较于 Face Mesh 算法,本文采用的 Attention Mesh 算法为 Face Mesh 的改进模型。该算法的优势在于:利用注意力机制专注于具有语义意义的面部区域,特别是眼睛和嘴唇,从而显著提高了这些区域的预测精度。具体来说,Attention Mesh 算法将整个模型划分为几个子模型,其中,一个子模型负责预测三维人脸网格的所有坐标,并为每个兴趣区域定义裁剪边界,其余子模型则依赖于通过注意力机制获取的  $24 \times 24$  特征图,以实现特定区域坐标的预测<sup>[9]</sup>。这一特性使得算法在处理重要面部区域特征点时能够提供更高的准确度。通过该算法的应用,能够实现对人脸各部位进行更为精准的检测和识别,从而提升整个疲劳监测系统的性能。

## 2 疲劳行为特征处理

现实生活中,常见的疲劳行为特征可分为3类:①反映眨眼行为的眼部纵横比<sup>[12]</sup>(eye aspect ratio, EAR)和眼睑闭合时间百分比<sup>[13]</sup>(percentage of eyelid closure over the pupil over time, PERCLOS),其中,EAR 主要用于检测眼睛的开合状态,其通过计算眼睛垂直方向距离与水平方向距离的比值来表示。②用于检测哈欠行为的嘴部纵横比<sup>[14]</sup>(mouth aspect ratio, MAR),其通过计算嘴部纵向距离与横向距离的比值来表示。③表征瞌睡点头行为的头部姿态自由度特征。其中,在进行眨眼与哈欠检测时,本文采用人脸 468 点关键点空间位置信息进行相关计算。然而,考虑到管制员在实际工作场景中需要频繁操作键鼠,可能会产生点头行为,因此,本文并未将头部姿态变化作为疲劳特征,以免引起误判。

### 2.1 眼部、嘴部纵横比函数重构

考虑到以往研究过程中大多采用二维关键点坐标作为变量构建纵横比函数,在一定程度上损失了空间特征信息,针对上述问题,本文采用人脸三维坐标信息,通过计算三维欧几里得距离,进一步重构眼部与嘴部的纵横比函数。该算法能够显著增强空间语义特征的丰富性,进而保证下游任务的质量。

三维空间欧几里得距离计算公式为

$$P_{ij} = \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2 + (z_j - z_i)^2} \quad (1)$$

式中:  $(x_i, y_i, z_i)$ 、 $(x_j, y_j, z_j)$  分别为空间两点坐标信息。

为确保计算精度和数据平滑性,选取眼部 10 个关键点进行三维纵横比函数重构,并分别计算左右两眼纵横比再取均值,将最终结果作为评估眼部状态特征的依据。该方法可以更准确地反映眼部状态,为后续疲劳监测任务提供更可靠的数据支持。其中,眼部关键点位置如图 2 所示。

$$E_{\text{left}} = \frac{P_{i=160,j=144} + P_{i=159,j=145} + P_{i=158,j=153} + P_{i=157,j=154}}{4P_{i=33,j=133}} \quad (2)$$

$$E_{\text{right}} = \frac{P_{i=384,j=381} + P_{i=385,j=380} + P_{i=386,j=374} + P_{i=387,j=373}}{4P_{i=363,j=263}} \quad (3)$$

$$E = \frac{1}{2} (E_{\text{left}} + E_{\text{right}}) \quad (4)$$

式中:  $E_{\text{left}}$  表示基于三维空间坐标点计算得到的左眼纵横比值;  $E_{\text{right}}$  表示基于三维空间坐标点计算得到的右眼纵横比值;  $E$  为二者均值。




图 2 眼部关键点示意图

Fig. 2 Schematic diagram of key points of eyes

在嘴部特征数据获取方面,本文选取该部位 8 个关键点(见图 3)进行三维纵横比函数重构,具体计算过程如下:

$$M = \frac{P_{i=81,j=178} + P_{i=13,j=14} + P_{i=311,j=402}}{3P_{i=62,j=293}} \quad (5)$$

式中:  $M$  表示基于三维空间坐标点计算得到的嘴部纵横比值。




图 3 嘴部关键点示意图

Fig. 3 Schematic diagram of key points of mouth

### 2.2 阈值标定

考虑到以往研究过程中,确定眼部与嘴部状态大多依赖 CNN 模型进行分类,尽管这些方法具有一定的泛化能力,但在面对由个体五官差异引起的识别误差时,会受到一定限制。鉴于此,本文提出采用特征匹配法逐样本进行状态阈值标定,具体如

下: 首先, 从 30 位管制员面部数据集中选取睁眼、闭眼、半睁眼、张口、闭口 5 种状态图像。其次, 结合关键点检测模型与眼部嘴部纵横比计算公式, 针对每位被试者在不同面部状态下的  $E$  值与  $M$  值进行详尽测定, 数据记录如表 1 所示。最后, 通过分析该数值, 可以为后续不同眼部嘴部状态的判定提供清晰且准确的阈值界限。该方法显著增强了系统对由个体五官差异所导致的纵横比值变化的适应能力, 进而有效降低了在后续疲劳状态监测过程中产生的误差。

表 1 眼部与嘴部状态纵横比标定结果

Table 1 Eye and mouth condition aspect ratio test results

样本	$M$		$E$		
	张口	闭口	睁眼	闭眼	半睁眼
1	0.083 43	0.008 57	0.328 91	0.092 35	0.258 65
2	0.060 12	0.009 36	0.296 43	0.162 26	0.276 24
3	0.079 35	0.008 39	0.375 25	0.077 34	0.246 03
4	0.047 42	0.002 35	0.418 82	0.165 48	0.250 76
5	0.042 38	0.006 88	0.401 13	0.103 96	0.249 75
⋮	⋮	⋮	⋮	⋮	⋮
26	0.042 87	0.004 48	0.406 54	0.139 43	0.226 81
27	0.066 04	0.006 97	0.451 01	0.161 59	0.273 71
28	0.049 23	0.001 91	0.415 33	0.127 62	0.223 96
29	0.107 38	0.003 37	0.408 61	0.107 79	0.243 97
30	0.045 62	0.004 96	0.362 13	0.083 65	0.196 03

以样本 1 为例, 针对眼部状态, 采用半睁眼状态的  $E$  值作为中心阈值 0.258 65, 并据此设定了上下浮动边界, 其中上限阈值设定为 0.32, 下限为 0, 连续 3 帧(可根据实际推理速度微调)小于中心阈值 0.258 65 判定为眨眼, 并进行眨眼计数。单帧  $E$  大于中间阈值判定为睁眼状态。在嘴部状态判定中, 基于闭口与张口状态的  $M$  值构建了一个数值区间(0.008~0.08), 以有效反映嘴部开闭的变化范围, 连续 3 帧(可微调)大于闭口纵横比值 0.008 57 判定为张口状态。

### 3 动态衰减时间窗口设计及疲劳判别

为更有效地监测管制员的疲劳状态, 本文提出了疲劳监测时间窗口动态衰减的方案, 旨在通过动态调整监测灵敏度, 能够实时、准确地反映管制员的疲劳程度。

同时, 考虑到管制员的实际工作特性, 引入管制员在岗时间、实时陆空通话负荷与疲劳事件发生次数 3 个指标作为时间窗口衰减速率的影响因子。3 个指标的选择依据如下: ①管制员的主要工作是通过陆空通话保障航空安全, 工作模式为

24 h 轮班制。尽管单次连续执勤时间不超过 2 h, 但在岗时间与管制员的生理状态存在显著相关性, 长时间在岗容易导致疲劳积累, 从而影响工作效率和安全性。②实时陆空通话负荷直接反映了管制员的工作强度。高负荷情况下, 管制员的精神和身体疲劳感会显著增加。③疲劳事件发生次数是衡量管制员疲劳程度的重要指标。

#### 3.1 动态衰减时间窗口设计

由于时间窗口衰减属于非线性过程, 本文通过大量实验, 选取非线性最小二乘法, 将衰减过程拟合至指数衰减形式, 有助于适应疲劳状态变化。

指数衰减函数是一种随着自变量的增加, 因变量以指数形式递减的函数, 可用于处理时间序列数据、模型参数衰减等问题, 在物理学中, 常用于描述运动物体动能衰减速率, 如物体运动时, 其动能随时间推移不断衰减的过程。

将本文研究场景进行迁移, 假设管制员的疲劳程度会随着在岗时间与语音频次的实时递增呈上升趋势, 动态时间窗  $W$  的衰减系数  $\lambda$  受到以上 2 个因素及表征疲劳事件(打哈欠、长时间半睁眼困倦)的偏置项影响。具体如下:

$$\lambda = \frac{kp}{\tau - 0.1b} \tag{6}$$

$$W = \alpha e^{-\lambda t} + \beta \tag{7}$$

式中:  $p$  为语音总频次, 表征实时陆空通话负荷;  $k$  为缩放因子, 对  $p$  进行合理映射, 此处取  $2 \times 10^{-6}$ ;  $\tau$  为衰减速率;  $b$  为疲劳事件记录数值; 0.1 为映射系数;  $t$  为测试时间, s;  $\alpha$  为函数饱和值;  $\beta$  为动态时间窗口函数偏置项, 表示时间窗口大小的下限。

实验开始前, 将初始时间窗口设置为 15 min, 最小时间窗口设置为 2 min, 并使用平均帧率为 55 帧/s 来计算  $W$  的值为 49 500。通过使用非线性最小二乘法进行函数拟合, 得到参数  $\alpha$  为 43 544.18,  $\tau$  为 5.96,  $\beta$  为 6 600。理想时间窗衰减曲线如图 4




图 4 理想时间窗衰减趋势

Fig. 4 Ideal time window decay trend

所示。该初始参数为后续实验中动态时间窗衰减计算提供了重要的参考依据。

### 3.2 基于面部特征的疲劳监测指标选取

考虑到该疲劳状态监测任务的待处理对象是具有时序关系的实时视频流序列,因此,需要同时关注单帧图像的空间维度信息和多帧之间的时序维度信息。针对以上问题,为了更好地衡量疲劳状态,提出使用可变时间窗内眨眼次数与时间窗口大小比值 $F_{\delta}$ 作为最终的疲劳判别依据。其中, $F_{\delta}$ 受在岗时间、实时语音频次与疲劳事件发生次数影响,具体如下:

$$F_{\delta} = \frac{\mu N_{\text{blink}}}{W} \quad (8)$$

式中: $N_{\text{blink}}$ 为动态时间窗内眨眼频次; $\mu$ 为尺度调整系数,本文取值为1000,用于将该指标的数值放大至与后续EEG疲劳指标相同的尺度。

### 3.3 疲劳判别流程

由于本文所探究的问题具有时序关系,在整个

处理流程中,将实时视频流作为输入,并对单帧图像进行串行处理,具体流程如图5所示。首先,使用提出的模型对图像进行面部关键点检测,并计算眼部和嘴部的纵横比。使用第2节所述方法对眼部与嘴部状态进行判断,并写入事件队列。其中,图5内的数值仅为示意值,实际数值需要根据个人的标定结果进行精确调整。其次,程序可以对长时间闭眼、半睁眼困倦与打哈欠3种重度疲劳事件进行判定并告警,具体方案如下:

1) 长时间闭眼:连续50帧(可微调)小于中间阈值0.25865,判定为长时间闭眼状态,进行告警提示。

2) 长时间半睁眼困倦:连续50帧(可微调)眼部纵横比处于中间阈值上下浮动区间内,判定为半睁眼昏睡状态,进行告警提示。

3) 打哈欠:由于打哈欠状态嘴部纵横比要大于常规值,设定连续120帧(可微调)嘴部纵横比大于张口阈值数值0.06,判定为打哈欠状态,进行告警提示。

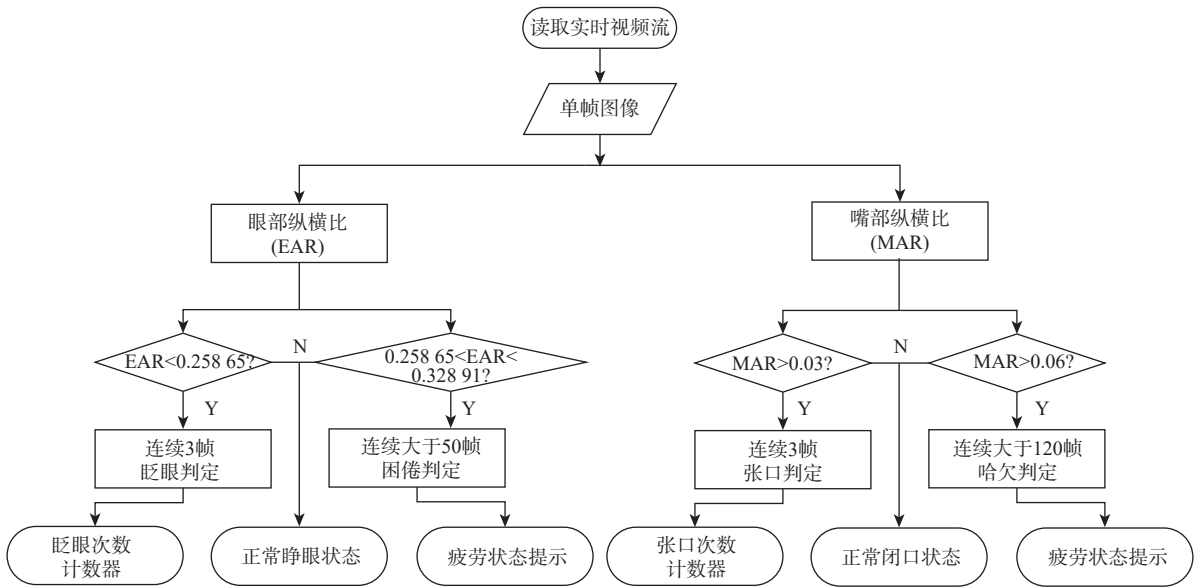


图5 视频流逐帧处理流程

Fig. 5 Flowchart of frame-by-frame video stream processing

最后,考虑到清醒状态下,人的眨眼频率通常在15~20次/min之间,通过时间与帧率的换算,将 $F_{\delta}$ 指标阈值设定为6.5,超过该阈值后,系统会进行疲劳判定并作出预警,以便管制员根据实际情况调整个人身体状态,预防因身体疲劳导致的空中交通管制不安全事件发生。

## 4 评价指标选取及实验设计

### 4.1 脑电疲劳指标选取

EEG作为一种生理电信号,具有较高的随机性,其节律种类繁多,不同的情绪、心理活动或外界

刺激均能影响其波形的变化。利用多导生理仪采集EEG的4种不同频率波,即 $\delta$ 波、 $\theta$ 波、 $\alpha$ 波和 $\beta$ 波。鉴于本文中管制员EEG采集涵盖了多个时间段,这些不同时间节点所呈现的精神状态存在一定变化。为使 $\theta$ 波和 $\beta$ 波特性和更具比较价值,选择借鉴迁移学习思想,使用驾驶员疲劳研究领域EEG相对功率谱的方法<sup>[15]</sup>,分析管制员EEG数据,该方法可提高所得疲劳指标的客观性与准确性。

由于实验中被试者并未达到沉睡状态,而 $\delta$ 波通常在成年人处于麻醉、沉睡或缺氧状态时出现<sup>[16]</sup>,故在不考虑 $\delta$ 波的前提下,将慢波与快波的相对功

率谱比值作为疲劳状态判断指标  $F_\epsilon$ , 具体如下:

$$F_\epsilon = P'_\theta / (P'_\alpha + P'_\beta) \quad (9)$$

式中:  $P'_\alpha$  为  $\alpha$  波的相对功率谱;  $P'_\beta$  为  $\beta$  波的相对功率谱;  $P'_\theta$  为  $\theta$  波的相对功率谱。

### 4.2 实验设计

本文的主要研究目标是通过基于面部特征信息对管制员的疲劳状态进行判别, 同时利用 EEG 指标对所获取的监测数据进行评估, 从而验证本文提出的疲劳监测算法的有效性。

为此, 实验采集了某管制单位 30 位成熟放单管制员的 EEG 数据与面部视频数据。其中, 30 位均为男性, 右利手, 年龄分布为 24~46 岁, 平均年龄为 27.63 岁; 岗龄分布为 2~25 年, 平均岗龄为 5.23 年。

实验场景为 5 个区域场景(对应 5 个扇区), 各练习难度等级相当, 采集管制员班后进行 35~60 min 管制测试的各项数据。当管制员处置不当出现 STCA 告警, 即短期冲突告警时, 则停止实验。测试过程中, 若出现 STCA 虚警可忽略, 若无 STCA 告警, 则以测试结束时间为停止条件, 具体实验结束时机由教员结合现场情况而定。

在数据采集方面, 面部视频数据通过 OBS Studio 配合 HP-w300 摄像头, 在屏幕正前方进行高清视频采集。同时, 鉴于相关研究<sup>[7]</sup>表明, 大脑前额皮质与高级认知功能紧密相关, 如决策制定、计划和注意力控制等, 因此, 在 EEG 数据收集方面使用 Mangold-10 多导生理仪, 采用单极导联法采集管制员左前额 Fp1 处的 EEG, 左耳后部为参考电极。

## 5 算法有效性分析

本节采用面部视频数据进行实验, 通过分析数据获得语音频次增长曲线和动态时间窗口大小的实际变化曲线, 具体单样本(被试者)数据示意如图 6 所示。在管制工作进行的过程中, 观察到语音频次随实际情况逐渐增加。与此同时, 在 0~20 min 的时间范围内, 动态时间窗口大小保持稳定(持续时间受单帧处理速度影响, 有轻微变化), 这一时段用于对  $F_\delta$  指标数据进行原始累积。在数据积累完成后, 动态时间窗口的尺寸受到累积阶段时间与语音频次的影响, 进行小范围骤降, 随后呈非线性递减趋势, 窗口下限设定为 1 min。其中, 算法内部的相关参数以第 3 节中理想参数为基础进行微调。

该算法的设计旨在通过动态调整时间窗口尺寸, 实时监测管制员的疲劳状态, 以便在疲劳早期和后期阶段提供不同的监测灵敏度, 从而缓解由于监测误差引起的误判现象。为防止漏检, 程序全程

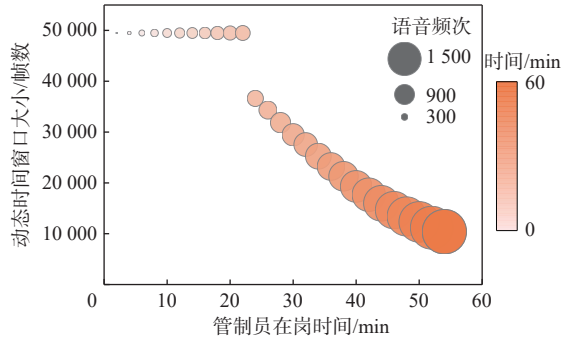


图 6 单样本语音频次与动态时间窗口大小关系

Fig. 6 Relation of single-sample speech frequency versus dynamic time window size

提供了疲劳事件(如打哈欠、长时间半睁眼困倦)的监测接口。同时, 疲劳事件的发生将直接影响时间窗口衰减速率, 以此来提高疲劳监测的灵敏度。

为验证本文算法的有效性, 通过对面部视频数据与 EEG 数据进行分析, 分别得到疲劳指标  $F_\delta$  与  $F_\epsilon$ , 并将 2 个指标数据在时间维度进行对齐。具体单样本被试者数据如图 7 所示。其中, 由于算法特性, 数据累积阶段的  $F_\delta$  值必然呈现单调上升趋势, 在后续分析中忽略该时间段数据。图 8 以小提琴图的形式直观呈现了针对单一被试者的疲劳指标数据分布。通过观察 2 组数据的中位数位置及小提琴图的宽度, 可以明显发现 2 个变量在中心趋势上呈现出显著的相似性, 并且数据在横轴上的分布相对均衡, 没有明显的偏态或集聚现象。




图 7 单样本疲劳指标关系

Fig. 7 Relation of single-sample fatigue indicator

在疲劳状态监测结果有效性分析方面, 选择使用 SPSS 对 30 个样本的  $F_\delta$  与  $F_\epsilon$  数据逐一进行双变量相关性分析, 完整计算结果如表 2 所示。通过观察结果可知, 在 30 个样本的双变量交叉相关性分析结果中, Pearson 相关性系数整体介于 0.462~0.785 之间, Sig. 双尾显著性检验均位于 0.01 级别, 相关性显著。

在算法对比实验中, 将本文算法(包括通过二

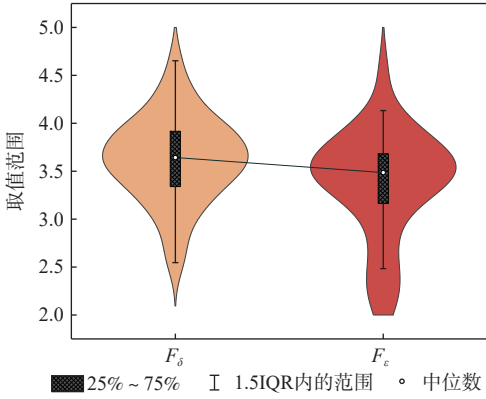


图8 单样本疲劳指标数据分布

Fig. 8 Data distribution of single-sample fatigue indicator

表2  $F_\delta$ 与 $F_\epsilon$ 相关性分析结果

Table 2 Results of correlation analysis between  $F_\delta$  and  $F_\epsilon$

被试者	个案数	Pearson相关性系数	Sig. (双尾)
1	36	0.462**	$5 \times 10^{-3}$
2	32	0.672**	$2.6 \times 10^{-5}$
3	40	0.591**	$6 \times 10^{-4}$
4	31	0.556**	$1 \times 10^{-3}$
5	29	0.522**	$4 \times 10^{-3}$
6	34	0.712**	$2 \times 10^{-6}$
7	26	0.506**	$8 \times 10^{-3}$
8	37	0.785**	$8.6 \times 10^{-9}$
9	25	0.646**	$4.8 \times 10^{-4}$
10	27	0.536**	$4 \times 10^{-3}$
11	27	0.724**	$2 \times 10^{-5}$
12	30	0.629**	$1.9 \times 10^{-4}$
13	24	0.653**	$5.4 \times 10^{-4}$
14	26	0.561**	$3 \times 10^{-3}$
15	24	0.517**	$1 \times 10^{-2}$
16	33	0.731**	$1 \times 10^{-6}$
17	28	0.623**	$3.9 \times 10^{-4}$
18	30	0.642**	$1.4 \times 10^{-4}$
19	25	0.583**	$2 \times 10^{-3}$
20	27	0.679**	$9.8 \times 10^{-5}$
21	36	0.482**	$3 \times 10^{-3}$
22	33	0.464**	$7 \times 10^{-3}$
23	29	0.651**	$1.3 \times 10^{-4}$
24	27	0.589**	$1 \times 10^{-3}$
25	35	0.703**	$2 \times 10^{-6}$
26	30	0.728**	$5 \times 10^{-6}$
27	25	0.622**	$8.9 \times 10^{-4}$
28	37	0.730**	$2.9 \times 10^{-7}$
29	23	0.561**	$5 \times 10^{-3}$
30	29	0.601**	$5.7 \times 10^{-4}$

注: \*\*表示在0.01级别(双尾), 相关性显著。

疲劳判别算法 FT-Only (分别为 FT-Only\_2D 和 FT-Only\_3D) 进行比较。结果表明, 相较于 FT-Only 算法, 本文算法在评估管制员疲劳状态时展现出了显著的性能提升, 具体如表 3 所示。

表3 算法对比分析结果

Table 3 Comparative algorithm analysis results

算法	平均Pearson相关性系数
FT-Only_2D	0.3529
FT-Only_3D	0.3816
本文算法(二维)	0.5992
本文算法(三维)	0.6154

由此, 可以验证本文算法, 在使用三维空间坐标计算眼部嘴部纵横比, 并融合管制员面部特征信息与其工作特性后, 能够在疲劳状态实时监测中达到接近基于 EEG 数据进行疲劳监测的效果, 为后续管制员无接触式疲劳监测及判别研究提供了相关思路。

## 6 结论

1) 针对现有通过管制员面部信息监测疲劳极少融合管制真实场景的特点, 提出一种融合管制工作相关特性的疲劳实时判别算法。

2) 通过采用 Attention Mesh 人脸关键点检测算法, 获取面部 468 点三维坐标信息, 使得该算法在稳定性、鲁棒性和推理速度方面表现优异, 能够显著提高下游任务的质量。

3) 该算法通过将管制员在岗时间、实时陆空通话负荷及疲劳事件发生次数作为动态时间窗口衰减速率的影响因子, 对时间窗口尺寸进行动态调整, 从而在不同的疲劳阶段提供不同的监测灵敏度, 有效缓解了由于监测误差引起的误判现象。

4) 本文将通过算法监测得到的指标  $F_\delta$  与疲劳监测“金标准”EEG 指标  $F_\epsilon$  进行相关性分析, 结果显示相关性显著, 且与其他算法相比效果更佳, 从而验证了本文算法的有效性与合理性。

后续在人脸追踪算法中可以结合多中心度量学习进行优化, 并进一步应用于面部疲劳监测任务, 以提升系统的整体性能和鲁棒性。本文算法基于 Windows 平台进行实验, 并未探究将该算法部署至边缘计算设备上的实时性、稳定性与可操作性。因此, 下一步会探索算法的部署优化及交互界面的设计。

## 参考文献 (References)

[1] LI K N, GONG Y B, REN Z L. A fatigue driving detection algorithm based on facial multi-feature fusion[J]. IEEE Access, 2020,

维坐标和三维坐标计算眼部嘴部纵横比的方式)与仅依赖面部特征, 特别是固定时间窗内眨眼频次的

- 8: 101244-101259.
- [2] JI Y Y, WANG S G, ZHAO Y, et al. Fatigue state detection based on multi-index fusion and state recognition network[J]. IEEE Access, 2019, 7: 64136-64147.
- [3] 汪磊, 孙瑞山. 基于面部特征识别的管制员疲劳监测方法研究[J]. 中国安全科学学报, 2012, 22(7): 66-71.  
WANG L, SUN R S. Research on fatigue monitoring method of controller based on facial feature recognition[J]. Chinese Safety Science Journal, 2012, 22(7): 66-71( in Chinese).
- [4] 史增鹏. 基于面部识别的管制员疲劳风险评估技术研究[D]. 天津: 中国民航大学, 2015.  
SHI Z P. Research on fatigue risk assessment technology for controllers based on facial recognition[D]. Tianjin: Civil Aviation University of China, 2015(in Chinese).
- [5] LAL S K L, CRAIG A. A critical review of the psychophysiology of driver fatigue[J]. Biological Psychology, 2001, 55(3): 173-194.
- [6] BERNHARDT K A, POLTAVSKI D, PETROS T, et al. The effects of dynamic workload and experience on commercially available EEG cognitive state metrics in a high-fidelity air traffic control environment[J]. Applied Ergonomics, 2019, 77: 83-91.
- [7] ARICÒ P, BORGHINI G, DI FLUMERI G, et al. Reliability over time of EEG-based mental workload evaluation during air traffic management (ATM) tasks[C]//Proceedings of the 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Piscataway: IEEE Press, 2015: 7242-7245.
- [8] 王莉莉, 殷硕峰, 马也. 基于轻量化 VIT 的面部疲劳监测算法研究[J]. 计算机仿真, 2025, 42(1): 317-322.  
WANG L L, YIN S F, MA Y. Research on facial fatigue monitoring algorithm based on lightweight VIT[J]. Computer Simulation, 2025, 42(1): 317-322(in Chinese).
- [9] GRISHCHENKO I, ABLAVATSKI A, KARTYNNIK Y, et al. Attention Mesh: high-fidelity face mesh prediction in real-time[EB/OL]. (2020-06-19)[2024-01-01]. <https://arxiv.org/abs/2006.10962>.
- [10] KARTYNNIK Y, ABLAVATSKI A, GRISHCHENKO I, et al. Real-time facial surface geometry from monocular video on mobile GPUs[EB/OL]. (2019-07-15)[2024-01-01]. <https://arxiv.org/abs/1907.06724>.
- [11] GROSSBERG M D, NAYAR S K. What is the space of camera response functions? [C]//Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2003.
- [12] 罗元, 云明静, 王艺, 等. 基于人眼信息特征的人体疲劳检测[J]. 计算机应用, 2019, 39(7): 2098-2102.  
LUO Y, YUN M J, WANG Y, et al. Human fatigue detection based on eye information characteristics[J]. Computer Applications, 2019, 39(7): 2098-2102(in Chinese).
- [13] GHODDOOSIAN R, GALIB M, ATHITSOS V. A realistic dataset and baseline temporal model for early drowsiness detection[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Piscataway: IEEE Press, 2019: 178-187.
- [14] WANG T S, SHI P F. Yawning detection for determining driver drowsiness[C]//Proceedings of the IEEE International Workshop on VLSI Design and Video Technology. Piscataway: IEEE Press, 2005: 373-376.
- [15] 王莉莉, 朱敏. 基于脑电数据的管制架次对管制员疲劳影响研究[J]. 中国安全科学学报, 2021, 31(2): 173-178.  
WANG L L, ZHU M. Research on influence of controlled sorties on controllers' fatigue based on EEG data[J]. China Safety Science Journal, 2021, 31(2): 173-178(in Chinese).
- [16] 陈彦峰. 睡意对脑电信号的影响[D]. 兰州: 兰州理工大学, 2013.  
CHEN Y F. The effect of drowsiness on electroencephalogram[D]. Lanzhou: Lanzhou University of Technology, 2013(in Chinese).
- [17] MOTTAGHY F M. Interfering with working memory in humans[J]. Neuroscience, 2006, 139(1): 85-90.

# Controller fatigue discrimination algorithm based on facial features

WANG Lili\*, YIN Shuofeng, PAN Yue

(ATM Operation Planning and Safety Techniques Key Laboratory of Tianjin, Civil Aviation University of China, Tianjin 300300, China)

**Abstract:** A real-time fatigue discrimination algorithm that takes into account the work characteristics of controllers is proposed in order to address the shortcomings of the current fatigue detection through facial information of controllers, such as the algorithm's low robustness and infrequent integration of the actual scene of control. Firstly, the Attention Mesh algorithm is used to obtain the 3D coordinate information of 468 points on the face, and the thresholds of eye and mouth aspect ratios are calibrated sample by sample using the feature matching method. Secondly, three indicators are introduced, namely, the controller's on-duty time, the real-time land and air call load, and the number of fatigue events, and these three indicators are dynamically mapped to the fatigue detection window through the exponential decay function and the fatigue frequency ratio of blinks within the dynamic decay time window is calculated through the calculation of the fatigue frequency ratio of blinks within the dynamic decay time window. The fatigue trend indicator is derived by calculating the percentage of blinking frequency within the dynamic decay time window. Finally, the EEG and facial video data of the post-shift control test of 30 mature release order controllers in the control room of a control unit are processed, and the fatigue indicator  $F_s$ , obtained from the facial data, is correlated with the EEG fatigue indicator  $F_e$  in the time dimension. The findings demonstrated that the validity and reliability of the suggested algorithms were confirmed, and the overall Pearson correlation coefficients in the bivariate cross-correlation analysis results of the 30 subject samples ranged from 0.462 to 0.785. The Sig. two-tailed significance tests were found at the 0.01 level, indicating a significant correlation.

**Keywords:** controller; fatigue discrimination; face keypoint detection; land and air call load; electroencephalogram signals