DOI:10.19652/j.cnki.femt.2406164

# 基于多特征经验融合的驾驶员疲劳状态检测方法*

丁福生 秦彦彬 张岚祥 吕红明
(盐城工学院汽车工程学院 盐城 224051)

**摘 要**:为解决驾驶员疲劳导致交通事故的问题,提出一种基于多特征经验融合的驾驶员疲劳状态视觉检测方法。首先,通过实时捕捉和提取驾驶员面部状态特征,包括眼部特征和嘴部特征,并采用经验融合模型对这些特征进行分析。接着,将多维度面部行为信息映射到卡罗林斯卡睡眠量表(KSS)分值,以此评估驾驶员的疲劳状态。最后,搭建实验验证了该检测方法的准确性、可靠性和有效性。实验结果表明,对于不同程度的疲劳状态,该方法的准确率分别为清醒状态90.34%,轻度疲劳90.17%,中度疲劳90.46%,重度疲劳97.67%。该检测方法能够准确评估驾驶员的疲劳程度,为提高行车安全性提供了有效的技术支持。

**关键词**:驾驶疲劳;疲劳检测;面部特征;特征融合;机器视觉
**中图分类号**:TN911.73;TP391.41 **文献标识码**:A **国家标准学科分类代码**:520.6040

# Driver fatigue detection method based on multi-feature empirical fusion

Ding Fusheng Qin Yanbin Zhang Lanxiang Lyu Hongming
(School of Automotive Engineering, Yancheng Institute of Technology, Yancheng 224051, China)

**Abstract**: To address the problem of traffic accidents caused by driver fatigue, this paper proposes a visual driver fatigue detection method based on multi-feature experience fusion. First, the driver's facial state features, including eye features and mouth features, are captured and extracted in real-time, and an experience fusion model is used to analyze these features. Then, the multi-dimensional facial behavior information is mapped to the Karolinska sleepiness scale (KSS) score to assess the driver's fatigue level. Finally, an experiment is conducted to verify the accuracy, reliability, and effectiveness of the detection method. The experimental results show that the accuracy of the detection method for different fatigue levels is 90.34% for the alert state, 90.17% for mild fatigue, 90.46% for moderate fatigue, and 97.67% for severe fatigue. This detection method can accurately assess the driver's fatigue level and provide effective technical support for improving driving safety.

**Keywords**: driver fatigue; fatigue detection; facial feature; feature fusion; machine vision

## 0 引 言

随着社会高速发展,汽车保有量的急剧增加直接导致交通事故频发,交通事故已成为困扰全球的重要社会问题之一[1]。据统计,10%~30%的交通事故与疲劳驾驶有关,其中特大交通事故的40%以上与疲劳驾驶有关[2-3]。疲劳驾驶指的是驾驶员在长时间、连续驾驶过程中,因生理和心理机能失调导致的驾驶技能下降现象[4]。此状态会严重削弱驾驶员的注意力、感知能力、思维判断以及运动协调能力,进而大幅增加道路交通事故的风险。因此,对疲劳驾驶检测的研究很有必要。

为了有效提升道路交通安全水平,疲劳驾驶的检测与预警显得尤为关键。目前,该领域的研究主要集中在3个方面。1)基于生物信号特征的疲劳驾驶检测,如通过心电图(electrocardiogram,ECG)、光电光容积描记术(photoplethysmograph,PPG)以及脑电信号等生物信号进行监测[5-6]。尽管这些方法具有较高的检测精度,但要求驾驶员佩戴专业设备,可能干扰正常驾驶,且成本较高[7-8]。

**收稿日期**:2024-06-12
* **基金项目**:国家自然科学基金面上项目(51875494)、江苏省研究生实践创新计划项目(KYCX24_XZ041)资助

2)基于车辆行为的疲劳状态检测,主要依据方向盘转角、座椅压力分布及制动踏板压力等车辆行为特征进行间接推断[9-10]。虽然操作不受干扰,但受天气、路况、车型和驾驶习惯等多种因素影响,其鲁棒性不足[11]。3)基于面部特征的疲劳检测,利用计算机视觉技术分析眼睛、表情等面部特征,具有非接触和无干扰的优势[12-13]。

尽管现有的视觉检测方法主要聚焦于面部特征,但仍面临诸多挑战[14]:1)实时性要求高,限制了部分高成本计算模型的应用,如深度学习模型;2)疲劳检测作为分类任务,其界定并不总是清晰,早期研究往往聚焦于特定疲劳行为,难以全面覆盖;3)构建多特征模型会引入额外的时间开销,使得计算密集型模型不宜采用;4)卡罗林斯卡睡眠量表(Karolinska sleep scale, KSS)标注的主观性性导致有监督学习方法训练的模型存在过拟合风险。

针对上述问题,本文综合考虑多种疲劳行为特征,开展基于面部特征的驾驶员疲劳状态检测研究,并使用KSS值和经验建立疲劳水平估计方法,以提高疲劳检测算法的准确性和可靠性。

## 1 多特征经验融合的疲劳估计模型

面部疲劳检测算法框架如图1所示。首先,根据驾驶员的自身情况和习惯,设定相应的阈值。然后,设置疲劳行为的KSS分数及其权重,将多维度的人脸行为特征有效地映射为与疲劳状态紧密相关的KSS值。最后,利用多特征经验融合模型,对驾驶员的疲劳状态进行判定。

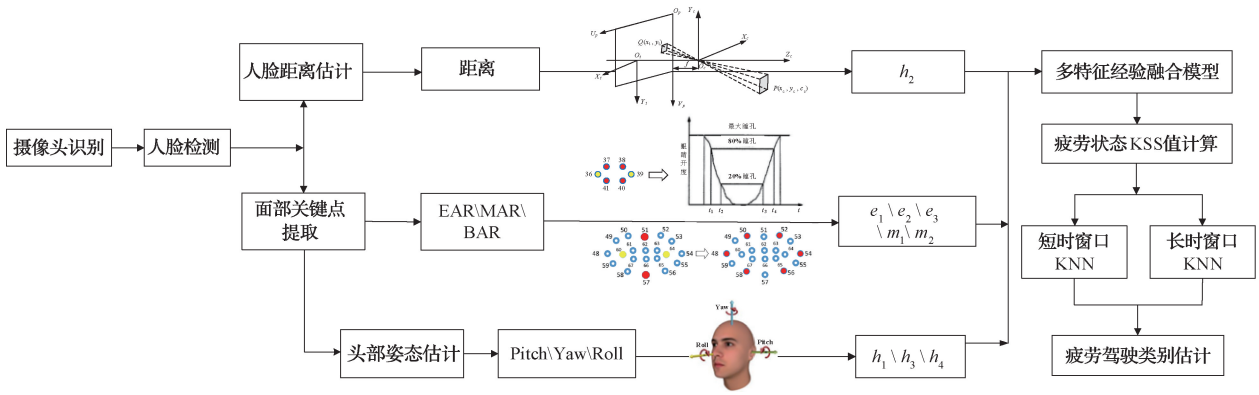


图1 面部疲劳检测算法检测框架

Fig. 1 Facial fatigue detection algorithm detection framework diagram

### 1.1 多特征融合方法

眼部纵横比(eye aspect ratio, EAR)[15]和嘴部纵横比(mouth aspect ratio, MAR)[16]是疲劳检测中两种广泛应用的特征指标。它们能够在面部距离变化时保持一定的稳定性,然而,这两种指标都不可避免地会受到头部姿态变化的影响。如果仅依赖EAR或MAR单一指标来判定疲劳状态,可能会因为驾驶员头部姿态的多样性而导致误判。为此,可利用多个面部特征来动态调整EAR和MAR的判定阈值。这种方法的核心思想在于,通过综合分析面部特征间的相对关系和变化规律,来更准确地反映驾驶员的疲劳状态。具体而言,利用面部特征点定位技术,实时跟踪驾驶员的眼睛和嘴巴区域,并计算其EAR和MAR值。同时,结合头部姿态信息,如俯仰角、偏航角等,对这些特征值进行动态调整。这种调整可以确保在不同头部姿态下,EAR和MAR都能作为有效的疲劳判定依据。

1)眼部特征检测

眼部特征检测部分的核心在于利用校准头部姿态后的自适应眨眼阈值adaptive_EAR_ threshold,结合EAR和单位时间里眼睛闭合时间所占百分比(PERCLOS)进行精细化的两阶段慢眨眼检测。EAR的计算依赖于眼睛内部关键特征点,如眼角、虹膜和眼尾的位置信息。当眼睛闭合时,这些特征点之间的距离会显著缩短,从而导致EAR值降低。PERCLOS作为一种广泛应用的评估指标,特别适用于疲劳驾驶和机组人员疲劳等场景。由于不同头部姿态下眼睛的形状和位置会发生明显变化,因此必须根据实时头部姿态信息对EAR阈值进行动态调整,以确保在各种姿态下都能准确检测眼睛的状态。

所谓的两阶段慢眨眼检测,实质上是根据眼睛闭合的持续时间将其分为两个不同阶段,慢眨眼和快眨眼。慢眨眼通常是指眼睛短暂闭合的状态,而快眨眼则指眼睛较长时间保持闭合的状态。这种分段式的检测策略有助于更精确地捕捉眼睛的动态变化,进而为后续的疲劳状态判定提供更为可靠的数据支持[17]。自适应眼部纵横比如图2所示。

EAR和PERCLOS计算公式如下:

$$EAR = \frac{distance\left(\frac{37+38}{2}, \frac{41+40}{2}\right)}{distance(36,39)} \tag{1}$$

$$PERCLOS = \frac{t_3 - t_2}{t_4 - t_1} \times 100\% \tag{2}$$

2)嘴部特征检测

嘴部特征检测主要通过提取人脸关键点来定位嘴部

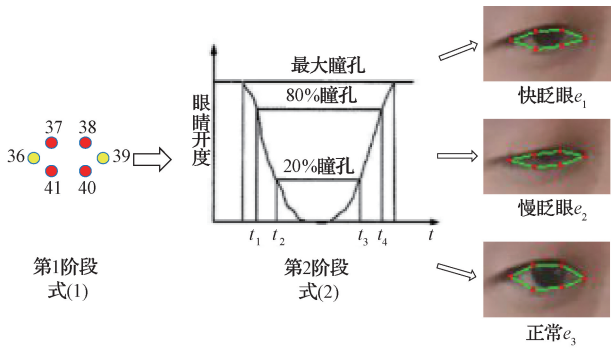


图 2　自适应眼部纵横比

Fig. 2　Adaptive eye aspect ratio

的特征点，进而分析嘴唇的形状和运动。这一过程结合了 MAR 和开口帧数(frame open mouth，FOM)进行两阶段的打哈欠检测如图 3 所示。MAR 作为一种有效的指标，用于检测嘴部是否处于打开状态。其计算原理在于比较嘴部上下唇之间的距离与左右唇之间的距离，当 MAR 值超过预设的阈值时，即被判定为嘴部打开。在哈欠检测中，则特别关注 MAR 值的变化趋势，通过捕捉这一动态变化来识别哈欠行为的起始和结束。FOM 则关注嘴巴在一段时间内的打开次数。通过统计开口帧数，可以量化嘴巴的活动频率。当 FOM 值超过设定的阈值时，将其视为哈欠行为的发生。这一指标提供了哈欠行为的另一种度量方式，有助于增强检测的准确性和可靠性。MAR 和 FOM 计算公式如下：

$$MAR = \frac{distance(51,57)}{distance(60,64)} \tag{3}$$

$$\begin{cases} x_i' = (x_i - x_0)\cos\theta - (y_i - y_0)\sin\theta \\ y_i' = (x_i - x_0)\sin\theta - (y_i - y_0)\cos\theta \end{cases} \tag{4}$$

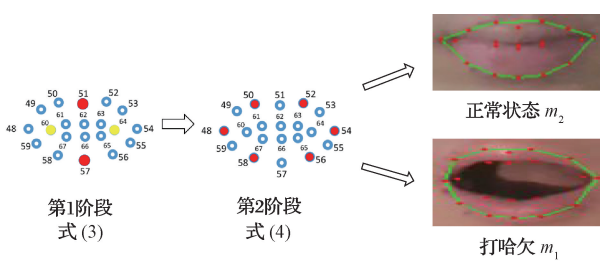


图 3　自适应嘴部纵横比

Fig. 3　Adaptive mouth aspect ratio

综合使用 MAR 和 FOM，可以有效提高哈欠检测的准确性和鲁棒性。哈欠检测流程通常分为两个阶段，第 1 阶段利用 MAR 进行初步筛选，当 MAR 值超过预设的阈值时，系统即认为可能发生了哈欠行为，从而触发第 2 阶段的检测。在第 2 阶段中，统计一定时间内的 FOM 值变化，即观察嘴巴打开的次数。若 FOM 值也超过设定的阈值，则综合判断为哈欠行为的发生。

$$MAR_{\text{thres}} = \begin{cases} MAR_{\text{init}} \times 1.3, & yaw < -6 \\ MAR_{\text{init}} \times 1.2, & -6 \leqslant yaw \leqslant -3 \\ MAR_{\text{init}} \times 1.0, & yaw > -3 \end{cases} \tag{5}$$

这种两阶段的检测方法结合了 MAR 和 FOM，能够更全面地捕捉哈欠行为的特征。同时，通过设定合理的阈值，可以有效区分正常说话、微笑等嘴部活动与哈欠行为，从而提高了检测的准确性。此外，这种方法对于不同驾驶环境和个体差异也表现出较强的适应性，增强了检测的鲁棒性。

### 1.2　多特征经验融合算法

在疲劳程度的定义中，通常采用基于困倦感受的 KSS 量表[18]进行数值评分，具体评分细节详见表 1。根据 KSS 值，可将疲劳状态划分为前期和后期两个阶段，以便更精确地识别和处理不同阶段的疲劳特征。

**表 1　困倦量化表**

**Table 1　Sleepiness quantification scale**

| 嗜睡程度 | 记分 |
|---|---|
| 极度警醒 | 1 |
| 非常警醒 | 2 |
| 警醒 | 3 |
| 有点警醒 | 4 |
| 既不警醒，也不犯困 | 5 |
| 有一些嗜睡征象 | 6 |
| 嗜睡，但还可以保持清醒 | 7 |
| 非常嗜睡，需要努力才能保持清醒 | 8 |

算法根据检测到的面部特征，对面部行为进行相应的编码，从而融合多种疲劳行为的检测结果，如表 2 所示。接着，依据经验为每种编码分配一个先验 KSS 值，如图 4 所示。例如，在疲劳后期，人们由于疲劳程度加深而频繁打哈欠，因此将打哈欠状态的 KSS 值设定为 7。为了提高对疲劳前期状态的识别准确性，确保为非明显疲劳行为设置的 KSS 值不低于 4。

**表 2　疲劳行为编码**

**Table 2　Fatigue behaviour coding**

| 行为方式 | | | | |
|---|---|---|---|---|
| 嘴巴 | 打哈欠 $m_1$ | 正常 $m_2$ | / | / |
| 眨眼 | 快眨眼 $e_1$ | 慢眨眼 $e_2$ | 正常 $e_3$ | / |
| 头部姿态 | 点头 $h_1$ | 前后倾 $h_2$ | 正常运动 $h_3$ | 静止 $h_4$ |

为了有效区分驾驶员的疲劳前期和后期状态，可采用不同长度的时间窗口进行检测。具体而言，对于疲劳前期的识别，选用较长的 240 帧时间窗口。以便捕捉和分析驾驶员在疲劳初期可能表现出的细微变化，实现早期预警。而对于疲劳后期的检测，则采用较短的 30 帧时间窗口，因为此时驾驶员的疲劳特征通常更为明显和急剧，需要更敏

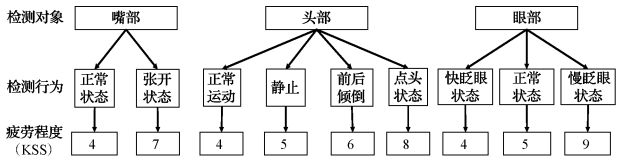


图 4　观测对象、观测行为以及疲劳程度值对应关系

Fig. 4　Correspondence between observation object, observation behaviour and fatigue level values

感和快速的检测机制来及时响应。这种差异化的时间窗口设置有助于更准确地识别驾驶员在不同疲劳阶段的状态。

在计算面部行为组合的 KSS 值时，引入 3 个 KSS 特征算子，singleton($f_1$)、mutual($f_2$)和 active/inhibit($f_3$)，旨在提高识别的准确。同时，进一步利用不同面部特征行为组合来区分疲劳行为，从而更全面地评估驾驶员的疲劳状态。

$$f_1 = \alpha \times KSS_n orm_{code_i} \times count_n orm_{code_i} \tag{6}$$

$$f_2 = \tanh(\beta(\sum_j (KSS_n orm_{code_j} \times count_n orm_{code_j}))) + \alpha \max_j (KSS_n orm_{code_j} \times count_n orm_{code_j}) \tag{7}$$

$$f_3 = \tanh(\beta(\sum_k (KSS_n \times count_n orm_{code_k}))) \tag{8}$$

式中：$KSS_n orm_{code_i}$ 代表疲劳行为编码 $code_i$ 的 KSS 归一化值，反映疲劳的严重程度；$count_n orm_{code_i}$ 是其频数归一化值，揭示该行为的相对发生频率。两者在评估中均起关键作用。tanh 函数是一种非线性的激活函数，它将输入值映射到范围[−1，1]。$\alpha$ 因子用于控制 KSS 值的变化速度，通过调整 $\alpha$ 的值，可以使模型对疲劳行为的响应更加平缓或迅速，从而满足不同的评估需求。$\beta$ 因子用来调节 tanh 激活函数中的疲劳行为组合的激活值。tanh 函数是一种将输入值映射到[−1，1]的非线性激活函数。通过引入 $\beta$ 因子，可以进一步控制疲劳行为组合在 tanh 函数中的激活程度，从而使得模型对疲劳状态的判定更加合理和准确。

$f_1$ 算子只针对眨眼、哈欠和点头 3 种明显疲劳行为，$h_1$、$m_1$ 和 $e_2$。通过初始赋予的高 KSS 值×统计次数，来计算后期疲劳得分。

$f_2$ 算子只针对头部前后倾，快眨眼等前期疲劳的人脸微行为，$h_2$、$e_3$、$h_4$、$e_3$。通过初始赋予的中 KSS 值×统计次数，接着使用 tanh 激活函数与 max 函数，来计算最大的前期疲劳得分。

$f_3$ 算子作用分别在 $f_1$、$f_2$ 算子上，更有利区分疲劳行为前期与后期。$f_3$ 算子对 $f_1$ 算子起到激活作用，通过放大后期疲劳得分，增强模型对后期疲劳状态的识别能力。同时，$f_3$ 算子对 $f_2$ 则算子起到抑制作用，通过降低前期疲劳得分，减少了模型对前期疲劳的误判率。这种双重作用机制使得检测方法在疲劳行为的整个过程中都表现出了更高的准确性和可靠性。

在驾驶员处于疲劳状态时，其最明显的疲劳行为包括慢眨眼和打哈欠，这些行为通常在疲劳后出现。因此，在模型设计中，这些行为用于疲劳后期的检测，以评估疲劳的程度。此外，头部的前后倾动作在疲劳初期检测中起到辅助作用。这种特殊的体态往往预示着驾驶员的不安或睡意初现，是早期疲劳的重要预警信号，可以作为疲劳前期检测的参考指标。因此，设计了图 5 所示的每个算子的疲劳组合，以便从多个角度综合判断驾驶员的疲劳状态。

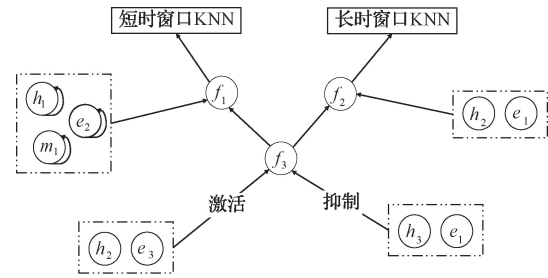


图 5　多种疲劳行为 KSS 值融合示意图

Fig. 5　Schematic diagram of KSS value fusion for multiple fatigue behaviors

完成多特征经验融合后，采用了两个 K 最近邻法(K-nearest neighbor，KNN)分类器来对驾驶员疲劳状态进行阶段划分，即区分疲劳前期和疲劳后期。具体而言，算法分别使用短时 KSS 窗口和长时 KSS 窗口的数据作为输入，通过之前训练好的两个 KNN 模型来进行层次化的疲劳程度评估。

在算法框架中，短时 KSS 窗口主要用于监测和识别疲劳的早期征兆，而长时 KSS 窗口则专注于捕捉和分析疲劳的后期表现。这种双窗口策略使得疲劳状态的检测更为精细化，能够从不同时间尺度上理解和判断驾驶员的疲劳状况。

将两个时间窗口的处理结果输入到它们各自对应的 KNN 模型中，即可完成对驾驶员疲劳状态的分类和评估工作。整个疲劳检测算法的流程如图 6 所示。

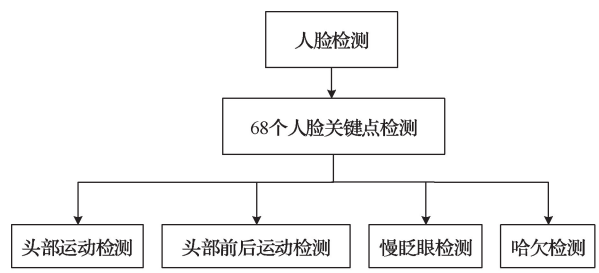


图 6　面部多特征经验融合疲劳检测算法示意图

Fig. 6　Schematic of facial multi-feature empirical fusion fatigue detection algorithm

算法的具体步骤如下：

1)使用 SCRFD-0.5GF 模型进行人脸检测，确保准确

捕捉到驾驶员的面部图像。

2)利用 MobileNetV3-56 模型检测 68 个人脸关键点，为后续的特征提取和分析提供基础数据。

3)通过 PnP(Perspective-n-Point)算法计算头部姿态的 3 个旋转自由度和 3 个平移自由度。进一步，计算各自由度的一阶差分并与阈值进行比较，从而进行点头、正常运动、头部静止和头部前后倾的检测。

4)利用小孔成像原理计算人脸与摄像头的距离，通过一阶距离差分和阈值判断，准确识别前后倾动作，这有助于判断驾驶员的疲劳状态。

5)基于校准的眼睛长宽比 EAR 和头部姿态的自适应眨眼阈值 adaptive_EAR_threshold，结合 EAR 和 PERCLOS 进行两阶段慢眨眼检测，以捕捉驾驶员的眼部疲劳特征。

6)采用基于头部姿态的哈欠检测算法，利用嘴部纵横比 MAR 和 FOM 进行两阶段哈欠检测，从而全面评估驾驶员的疲劳程度。

## 2 实验以及结果分析

实验平台主要由中央控制单元、摄像头、喇叭和总线组成，它们共同构建了一个完整的实验环境，安装在实验车内以便于实时采集和分析驾驶员的疲劳状态数据，如图 7 所示。

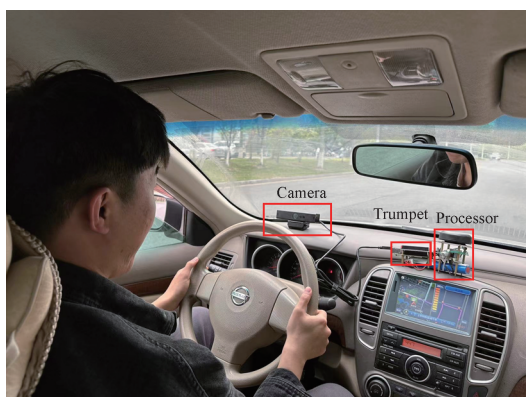


图 7 实验平台

Fig. 7 Experimental platform

### 2.1 数据准备

实验采用自制的混合数据集，该数据集涵盖了清醒(A0)、轻度疲劳(A1)、中度疲劳(A2)和重度疲劳(A3)4 种精神状态类别。这样的设计不仅全面反映了驾驶员从清醒到重度疲劳的连续变化过程，还有助于深入研究疲劳程度对检测算法性能的影响。

在数据结构上，通过网络采集和视频数据库采集两种方式，共获得了丰富的样本图像。网络采集部分提供了总计 1 671 张样本图像，其中清醒状态 432 张，轻度疲劳 437 张，中度疲劳 435 张，重度疲劳 367 张。这些图像来源多样，包含了不同的环境和场景，为模型的泛化能力提供了有力的支持。同时，视频数据库采集部分则来源于分辨率为 780×580、帧率为 60 fps 的高清视频流，确保了图像的清晰度和细节信息的完整性。在此部分，共收集了 3 104 张样本图像，其中清醒状态 761 张，轻度疲劳 774 张，中度疲劳 737 张，重度疲劳 832 张。这些高质量的图像数据为模型的训练和验证提供了坚实的基础。综合两部分数据，清醒状态共有 1 243 张样本图片，轻度疲劳共有 1 363 张样本图片，中度疲劳共有 1 241 张样本图片，而重度疲劳共有 1 353 张样本图片。部分数据集的示例如图 8 所示。

图 8 部分数据集

Fig. 8 Selected datasets

### 2.2 实验分析

为了全面评估本文算法的性能，采用了分层抽样法，将其与传统支持向量机(SVM)、径向基神经网络(RBF)、贝叶斯分类(BC)和随机森林(RF)等模型进行了比较[19]。在比较过程中，确保了各类别中的样本分布均衡，并根据预先设定的标准，从不同类别中随机选择了一定数量的样本进行测试和评估。在构建对比模型时，RF 模型融合了 SVM 的决策树，SVM 模型采用了粒子群优化算法(PSO)进行参数调优，RBF 模型结合了自组织映射神经网络(SOM)进行特征映射，而 BC 模型则基于主成分分析(PCA)进行特征降维和分类。此外，考虑到疲劳驾驶系统对实时性的要求，还特别关注了算法的运行时长性能，即单次识别过程的耗时情况。

各种算法的测试结果比较情况如表 3 所示。有关检查状态如图 9 所示。

**表 3 各种算法的测试结果比较**

**Table 3 Comparison of test results of various algorithms**

| 模型 | 准确率/% | | | | 耗时/ms |
|---|---|---|---|---|---|
| | A0 | A1 | A2 | A3 | |
| SVM | 85.64 | 87.75 | 90.43 | 94.84 | 35 |
| RBF | 85.62 | 87.23 | 91.51 | 95.56 | 97 |
| BC | 86.07 | 88.31 | 90.11 | 94.18 | 38 |
| RF | 86.25 | 88.40 | 91.64 | 96.94 | 39 |
| 本文 | 90.34 | 90.17 | 90.46 | 97.67 | 38 |

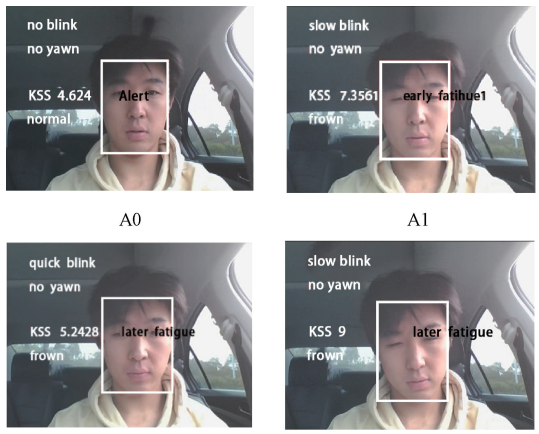


A0 A1 A2 A3

图 9 检查状态图

Fig. 9 Check status charts

可以看出，本文提出的多特征融合算法在不同疲劳状态下的检测准确率均表现出色，尤其是在 A0、A1 和 A3 状态的检测上，其准确率明显优于其他算法，A2 状态的检测准确率仅略低于 RBF 和 RF 算法。这充分证明了多特征融合算法在疲劳检测中的准确性和有效性。同时，本文算法的运行耗时相对较短，这得益于算法在每一步检测过程中的优化和轻量化设计，以及多特征并行检测策略的运用，有效提高了计算效率和降低了消耗时间。

### 2.3 验证实验

为了验证算法在实际应用中的可靠性和有效性，采用人为模拟的方式来获取驾驶员在不同疲劳状态下的样本数据。数据集共包含 400 个清醒驾驶样本，其中包括了 50 个含有诸如交谈等干扰场景的样本，以模拟真实驾驶环境中的复杂情况。此外，还采集了 350 个轻度疲劳样本和 355 个重度疲劳样本，以覆盖不同疲劳程度的驾驶状态。每个疲劳样本的持续时间范围控制在 3～8 min，以确保数据的真实性和可靠性。

在疲劳状态人为模拟的情况下，进行了综合评价算法准确性测试，结果如表 4 所示。测试结果表明，多特征融合算法在检测疲劳驾驶行为方面具有较高的准确率，显示出其在实际应用中的潜力和价值。然而，在所有测试视频中，算法仍然存在一定的误差和漏检情况。这可能与疲劳状态的持续时间和疲劳程度的差异有关。当疲劳状态持续时间较短或疲劳程度较轻时，算法可能难以准确捕捉到相关特征，从而导致漏检。

**表 4 综合评价算法准确性**

**Table 4 Comprehensive evaluation algorithm accuracy**

| 视频 | 总帧数 | 正确数 | 误差 | 漏检 | 判断正确率/% |
|---|---|---|---|---|---|
| A | 240 | 230 | 1 | 9 | 94.93 |
| B | 240 | 239 | 1 | 0 | 95.58 |
| C | 240 | 238 | 1 | 1 | 95.16 |
| D | 240 | 237 | 3 | 0 | 93.75 |

## 3 结 论

为了及时识别驾驶员的疲劳状态并进行干预，预防和减少交通事故的发生，本文提出了一种基于面部多特征融合的驾驶员疲劳状态检测方法。通过引入 KSS 值，并基于经验构建疲劳水平估计模型，能够提升疲劳检测算法的准确性和可靠性。在相关数据集上的实验结果表明，该方法对于清醒、轻度疲劳、中度疲劳以及重度疲劳具有较高的检测准确率，并且在检测过程中耗时较短，能够满足实时性要求。

在今后的研究中，需引入更多的训练样本，并引入注意力机制等方法，以及进一步优化算法，来减少驾驶员背景环境等因素的干扰，进而提升疲劳检测的准确性和稳定性。同时，为了确保检测方法在实车环境中的应用效果，还需要对算法的功耗、可靠性及安全性进行全面评估与研究。

### 参 考 文 献

[1] PHILLIPS ROSS O. A Review of definition fatigue-and a step towards a whole definition [J]. Transportation Research Part F: Traffic Psychology and Behaviour, 2015, 29:48-56.

[2] CHOWDHURY A, SHANKARAN R, KAVAKLI M, et al. Sensor applications and physiological features in drivers' drowsiness detection: A review [J]. IEEE Sensors Journal, 2018, 18(8): 3055-3067.

[3] KHUMPISUTH O, CHOTCHINASRI T, KOSHAKOSAI V, et al. Driver drowsiness detection using eye-closeness detection [C]. 2016 12th International Conference on Signal Image Technology & Internet-Based Systems(SITIS), 2016:661-668.

[4] VENKATA PHANIKRISHNA B, JAYA PRAKASH A, SUCHISMITHA C. Deep review of machine learning techniques on detection of drowsiness using EEG signal [J]. IETE Journal of Research, 2023, 69(6): 3104-3119.

[5] 张亚龙，张世武，孙帅帅，等. 融合肌电信号与 A 型超声的新型肌肉疲劳检测方法[J]. 电子测量与仪器学报，2022，36(6)：13-21.
ZHANG Y L, ZHANG SH W, SUN SH SH, et al. Muscle fatigue detection method with fusion of EMG signal and A-type ultrasound [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(6):13-21.

[6] SUN Z C, MIAO Y N, JEON J Y, et al. Facial feature fusion convolutional neural network for driver fatigue detection [J]. Engineering Applications of Artificial Intelligence, 2023, 126, Part C: 106981.

[7] AHMED S, LEE Y, LIM Y H, et al. Noncontact

assessment for fatigue based on heart rate variability using IR-UWB radar [J]. Scientific Reports, 2022, 12: 14211.

[8] 谢平,齐孟松,张园园,等.基于多生理信息及迁移学习的驾驶疲劳评估[J].仪器仪表学报,2018,39(10):223-231.
XIE P, QI M S, ZHANG Y Y, et al. Driver fatigue assessment based on multi-physiological signals and transfer learning [J]. Chinese Journal of Scientific Instrument, 2018,39(10):223-231.

[9] 程泽,林富生,靳朝,等.基于轻量化卷积神经网络的疲劳驾驶检测[J].重庆理工大学学报(自然科学版),2022,36(2):142-150.
CHENG Z, LIN F SH, JIN ZH, et al. Fatigue driving detection method based on lightweight convolutional neural network [J]. Journal of Chongqing University of Technology (Natural Science), 2022, 36(2): 142-150.

[10] 徐莲,任小洪,陈闰雪.基于眼睛状态识别的疲劳驾驶检测[J].科学技术与工程,2020,20(20):8292-8299.
XU L, REN X H, CHEN R X. Detection to fatigue driving based on eye state recognition [J]. Science Technology and Engineering, 2020, 20(20): 8292-8299.

[11] CHEN L, XIN G J, LIU Y L, et al. Driver fatigue detection based on facial key points and LSTM [J]. Security and Communication Networks, 2021, 2021: 5383573.

[12] KUMAR A, KOMARAGIRI R, KUMAR M. A review on computation methods used in photoplethysmography signal analysis for heart rate estimation [J]. Archives of Computational Methods in Engineering, 2022, 29(2): 921-940.

[13] 任建新,许锋.多特征融合的驾驶员疲劳程度量化方法研究[J].电子测量技术,2023,46(20):16-23.
REN J X, XU F. Research on the quantification method of driver fatigue level by fusing multiple features [J]. Electronic Measurement Technology, 2023,46(20):16-23.

[14] PARSA M J, JAVADI M, MAZINAN A H. Fatigue level detection using multivariate autoregressive exogenous nonlinear modeling based on driver body pressure distribution [J]. Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering, 2022, 236(1): 168-184.

[15] ZHAO G, HE Y, YANG H, et al. Research on fatigue detection based on visual features [J]. IET Image Processing, 2022, 16(4): 1044-1053.

[16] MBOUNA R O, KONG S G, CHUN M G. Visual analysis of eye state and head pose for driver alertness monitoring [J]. IEEE Transactions on Intelligent Transportation Systems, 2013, 14(3): 1462-1469.

[17] 田璐萍,嵇启春.基于眼部信息融合的疲劳驾驶检测的研究[J].国外电子测量技术,2019,38(10):26-29.
TIAN L P, JI Q CH. Study on fatigue driving test based on eye information fusion [J]. Foreign Electronic Measurement Technology, 2019,38(10): 26-29.

[18] ÅKERSTEDT T, GILLBERG M. Subjective and objective sleepinessin the active individual [J]. International Journal of Neuroscience, 1990, 52(1—2): 29-37.

[19] GANESAN S, MANOUSAKIS J E, MULHALL M D, et al. Sleep, alertness and performance across a first and a second night shift in mining haul truck drivers [J]. Chronobiology International, 2022, 39(6): 769-780.

## 作 者 简 介

丁福生,硕士,讲师,主要研究方向为汽车自动驾驶、计算机视觉。
E-mail: dfs_ycit@163.com

秦彦彬(通信作者),硕士研究生,主要研究方向为深度学习、计算机视觉。
E-mail: qinyanbin1@aliyun.com

张岚祥,硕士研究生,主要研究方向为计算机视觉、汽车安全驾驶。

吕红明,博士,教授,主要研究方向为汽车动力学分析与控制。