低光环境下的驾驶员疲劳检测方法

姚 伟
安徽理工大学 计算机科学与工程学院, 安徽 淮南 232001

摘 要:目的 驾驶员疲劳是导致交通事故的主要因素之一,尤其在夜间低光照环境下,疲劳检测变得更加具有挑战性。针对低光环境下驾驶员面部特征提取困难的问题,提出了一种融合局部全局特征的低光照环境驾驶员疲劳检测方法。**方法** 该方法包括低光增强模块和双流网络检测模块。低光增强模块是在多分枝弱光增强网络(MBLLEN)的特征提取层添加通道注意力(SE-Net)模块,提高低光增强算法对驾驶员面部特征信息的关注,更好地增强了夜间驾驶员的低光图像。双流网络检测模块使用双分支网络结构,分别提取全局面部信息和局部面部信息。首先,驾驶员原始的夜间图像经过低光增强算法增强;然后,输入双流网络中,双分支结构网络分别使用 ResNet-34 和 ResNet-18 提取全局特征和局部特征;最后,通过集成学习方法将局部和全局特征信息融合,以不同权重贡献比的方式生成最终的疲劳状态预测。**结果** 实验结果表明:提出的方法在 NTHU-DDD 数据集上表现出良好的性能,最终的检测准确率为 90.10%。**结论** 文中提出的方法在夜间驾驶员疲劳检测方面表现出较高的准确性,为夜间驾驶员疲劳检测领域带来了重要的进展,具有深远而重要的意义。

关键词:疲劳检测;低光增强;双分支网络;集成学习
中图分类号:U463.6;TP391.41;U492.8 **文献标识码:**A doi:10.16055/j.issn.1672-058X.2025.0002.010

Driver Fatigue Detection Method in Low-light Environments

YAO Wei
School of Computer Science and Engineering, Anhui University of Science and Technology, Anhui Huainan 232001, China

Abstract: Objective Driver fatigue is a major factor contributing to traffic accidents, especially in low-light environments at night, where fatigue detection becomes more challenging. To address the difficulty in extracting the facial features of drivers under low-light conditions, a method combining local and global features was proposed for driver fatigue detection in low-light environments. **Methods** The proposed approach comprised a low-light enhancement module and a dual-stream detection module. The low-light enhancement module incorporated a channel attention mechanism (SE-Net) into the feature extraction layer of the multi-branch low-light enhancement network (MBLLEN). This enhanced the algorithm's focus on the driver's facial feature information, improving the quality of low-light images of drivers at night. The dual-stream detection module employed a dual-branch network structure to extract global and local facial features. First, the original nighttime images of drivers were enhanced using the low-light enhancement algorithm. These enhanced images were then input into the dual-stream network, where the two-branch structured network used ResNet-34 and ResNet-18 to extract global and local features, respectively. Finally, the local and global feature information was fused using an ensemble learning method, and the final fatigue state prediction was generated with different weight contribution ratios. **Results** The experimental results show that the proposed method exhibited good performance on the NTHU-DDD dataset,

收稿日期:2023-09-20 **修回日期:**2023-11-18 **文章编号:**1672-058X(2025)02-0071-07
作者简介:姚伟(1999—),男,安徽合肥人,硕士研究生,从事驾驶员疲劳检测研究.
引用格式:姚伟. 低光环境下的驾驶员疲劳检测方法[J]. 重庆工商大学学报(自然科学版),2025,42(2):71-77.
YAO Wei. Driver fatigue detection method in low-light environments[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2025, 42(2): 71-77.

and the final detection accuracy was 90.10%. **Conclusion** The method proposed in this paper shows high accuracy in nighttime driver fatigue detection and brings important progress in the field of nighttime driver fatigue detection, which is of far-reaching and important significance.

Keywords: fatigue detection; low-light enhancement; dual-branch network; ensemble learning

1 引 言

疲劳驾驶是导致交通事故的重要原因之一,一直备受关注。根据中国交通部的研究[1],每年有 90 多万人因疲劳驾驶而不幸丧生,这一数字占交通事故导致死亡人数的 6%以上。尽管一些机构和部门已经采取了一些措施来限制疲劳驾驶,但是由于生活和工作的原因,仍然有许多驾驶员难以避免陷入疲劳驾驶的境地。

近年来,随着深度学习技术的不断进步和深度学习硬件设备性能的不断提升,基于驾驶员面部特征的检测方法[2]已经成为最主要的驾驶员疲劳检测方法。夜晚是驾驶员疲劳高发时段,光线不足导致摄像头捕获图像质量下降,包括图像噪声、模糊和低对比度等问题,难以清晰显示驾驶员面部特征。这种低光条件下,疲劳检测算法难以准确识别面部特征,影响了检测的准确性。为此,Shen 等[3]提出了 AAQR 的自适应衰减量化 Retinex 方法,该方法包括 3 个关键阶段:衰减限制、衰减预测和自适应量化,有效应对夜间驾驶员面部检测中因光照不足而引发的问题,但是该方法对噪声较为敏感,可能导致误检测或漏检;黄振宇等[4]对低光增强算法 Zero-DCE 进行了改进,引入上下采样结构和核选择模块以减少噪声的影响,采用注意力门控机制来增强网络对图像中人脸区域的敏感性,提高了对低光人脸图像的增强效果,但是此方法的复杂性过高,可能不适用于资源有限的车载设备;朱艳等[5]利用深度视觉传感器捕获驾驶员图像,并通过最小二乘法拟合眼睛和嘴巴的轮廓来计算开合度等特征构建疲劳检测系统,该方法仍然受到低光环境下面部特征模糊或变形的干扰,并不能解决低光环境下的噪声影响;Mandal 等[6]提出一种低光照条件下的驾驶员视觉增强技术,该技术基于修正的亮通道先验,并采用自适应伽马校正方法,成功提升了夜间图像的光照质量,但是该方法没能充分提取驾驶员面部特征信息。

尽管上述方法在低光环境下驾驶员疲劳检测中取得了一定的进展,但大多数方法都存在低光图像增强效果不佳或面部特征信息提取不足等问题。为此,本文提出了一种用于低光照条件下驾驶员疲劳检测的方法,其中包括两个关键模块:低光增强模块和双流网络检测模块。低光增强模块旨在解决夜间驾驶中由于图像模糊导致特征信息提取不足的问题;双流网络检测模块充分提取不同的特征信息,以不同的权重贡献方式将局部和全局特征信息融合,显著提升了驾驶员疲劳检测效果。

2 检测系统设计

2.1 整体框架

本文提出的方法框架如图 1 所示。首先,夜间低光照下的驾驶员图像输入网络,经过低光增强模块的处理,得到增强后的图像,作为接下来疲劳检测模块的输入。疲劳检测网络由双分支构成,分别是局部特征提取网络和全局特征提取网络。最终,通过对双分支网络输出的信息以不同权重贡献进行线性融合,得出准确的驾驶员疲劳状态检测结果。

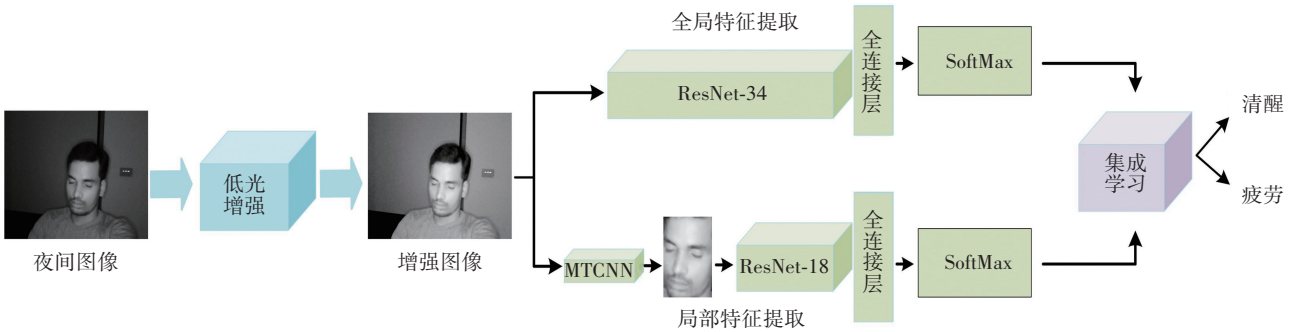

图 1 方法的结构框架

Fig. 1 Structural framework of the proposed method

2.2 低光增强模块

在夜间驾驶中,光照条件较差,图像中存在很多噪声和无关信息,而疲劳状态常以微小的面部活动和眼部运动等微妙特征变化来体现,所以模型需要更加关

注有效的信息。因此,本文在多分支弱光增强网络(MBLLEN)[7]基础上引入 SE 通道注意力模块[8],使网络集中注意于疲劳检测任务中的重要区域和特征,提高网络对关键区域的感知能力,加强模型对于微妙面部特征的捕捉,结构如图 2 所示。

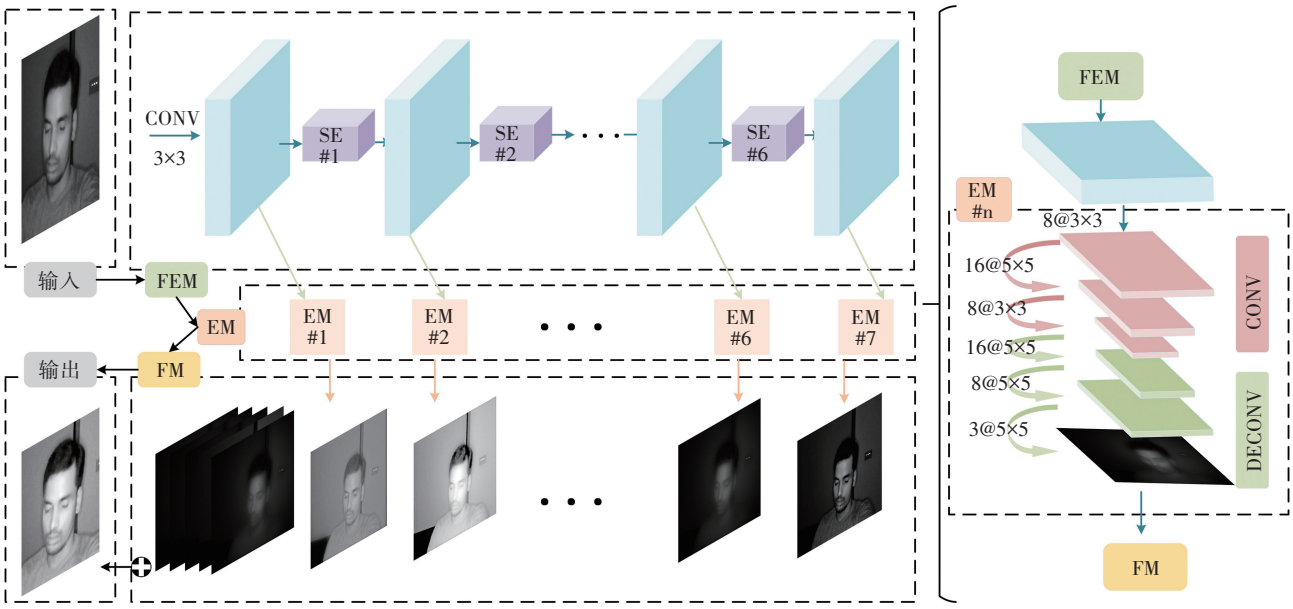

图 2　低光增强模块框架

Fig. 2　Framework of the low-light enhancement module

特征提取模块(FEM)包含 7 个卷积层和 6 个 SE 注意力模块,每个卷积层的输出成为下一层卷积层和对应增强模块(EM)的输入。EM 模块包含 6 个卷积层,采用对称结构。第一层是 8 通道的 3×3 卷积层,第二层是 16 通道的 5×5 卷积层,最后 3 层为反卷积层,通道数分别为 16、8、3,卷积核尺寸都为 5×5。特征融合模块(FM)将 EM 网络输出的特征图堆叠,使用 1×1 卷积核进行融合,实现对所有特征图参数的加权求和。

FEM 模块中,相邻卷积层之间引入 SE 注意力模块,SE 模块旨在保留原始特征的基础上,通过学习不同通道之间的关系,提升模型的表现能力。

首先,SE 模块通过空间维度的压缩,将原始特征图 $X \in R^{H\times W\times C}$ 的维度变为 1×1×C。其中,H、W、C 分别为输入特征图的高、宽和通道数,使其具备一定的全局信息。Squeeze 操作如式(1):

$$z_c = F_{sq}(u_c) = \frac{1}{H \times W}\sum_{i=1}^{H}\sum_{j=1}^{W} \boldsymbol{u}_c(i,j) \tag{1}$$

F_{sq} 为 Squeeze 操作,z_c 表示经过 Squeeze 操作后特征图第 c 个通道的值,$\boldsymbol{u}_c$ 为原始特征图中的第 c 个通道的二维矩阵。

然后,通过激励操作,使用小型全连接层和激活函数为每个通道生成权重 s,通过学习权重捕捉特征通道之间的相关性。Excitation 操作如式(2):

$$s = F_{ex}(z,W) = \sigma(g(z,W)) = \sigma(W_2\delta(W_1 z)) \tag{2}$$

F_{ex} 为 Excitation 操作,z 为特征图通道的压缩表示,σ 为 Sigmoid 激活函数,$g(z,W)$ 表示包含两个隐藏层的全连接计算,W_1 和 W_2 为两个全连接层的权重。最后,通过 Scale 操作将各个通道权重与原始特征图的各个通道进行点乘操作,获得重新加权的特征图 $\tilde{x}_c$,使网络更加关注有效特征。特征图计算如式(3):

$$\tilde{x}_c = F_{\text{scale}}(\boldsymbol{u}_c, s_c) = s_c \cdot u_c \tag{3}$$

通过这种方式,SE 模块适应性地调整通道注意力,有助于优化特征表示,显著提升对夜间低光照下驾驶员图像的提取与增强效果。

2.3　双流网络检测模块

传统疲劳检测网络通常采用单一分支结构,只关注全局特征或局部特征。本文采用双分支结构充分考虑了两者的重要性,全局特征可以提供驾驶员面部全局信息,而局部特征可以捕捉驾驶员精确的眼部状态和嘴部状态,结合全局和局部特征信息使得预测驾驶员疲劳状态的准确性大大增加。

双分支结构中的特征提取部分采用了残差连接(Residual Connection)的 ResNet-18 网络和 ResNet-34 网络[9]。残差结构将前一层的输出与通过该层的权重

参数进行处理后得到的结果相加,而不是完全替代前一层的输出。这样的操作允许网络学习差异或残差,从而更好地表示输入数据。残差的操作如式(4):

$$Y=F(x,\{w_i\})+x \tag{4}$$

Y 为当前层的输出,x 为前一层的输出,$F(x,\{w_i\})$表示非线性映射或变换的函数,它使用权重参数$\{w_i\}$对输入的 x 进行处理。

残差的使用使得双流检测网络逐层提取图像中的特征,保留输入数据的特征信息,而不是完全替代它,有利于驾驶员疲劳检测的任务,因为它可以防止丢失重要的低级特征,如面部表情的细节。

具体而言,增强后的驾驶员图像输入到双流网络中,全局特征提取网络直接使用全局图像作为输入,局部特征提取网络会对全局图像进行处理,使用多任务卷积神经网络(MTCNN)获取驾驶员的人脸框。将人脸框裁剪后作为局部图像,输入局部特征提取网络中,检测网络中保留了 ResNet-18 和 ResNet-34 的特征提取部分,并在其之后添加一个全连接层和 SoftMax 激活函数,各分支网络可以将学习到的特征映射到“瞌睡”和“非瞌睡”状态的概率。最后,通过集成学习方法,将两个分支网络的输出进行权重分配,得到最终的疲劳状态预测结果。

集成学习方法是通过对两个双分支网络赋予不同的权重 w_1 和 w_2,权重表示单个网络对整个网络的贡献度,其中 w_1 为全局特征网络的权重贡献,w_2 为局部特征网络的权重贡献。这两项关键参数均由各自分支网络在训练过程中获得,其中 $w_1=0.553$,$w_2=0.736$。结合两个分支网络输出的概率,疲劳预测概率由式(5)可得:

$$y=\frac{w_1\times y_1+w_2\times y_2}{w_1+w_2} \tag{5}$$

y 是模型预测的概率,y_1 和 y_2 分别是全局特征提取网络和局部特征提取网络输出的预测概率,w_1 和 w_2 分别是全局特征提取网络和局部特征提取网络的权重贡献。图 3 展示了双流网络检测模块的结构。

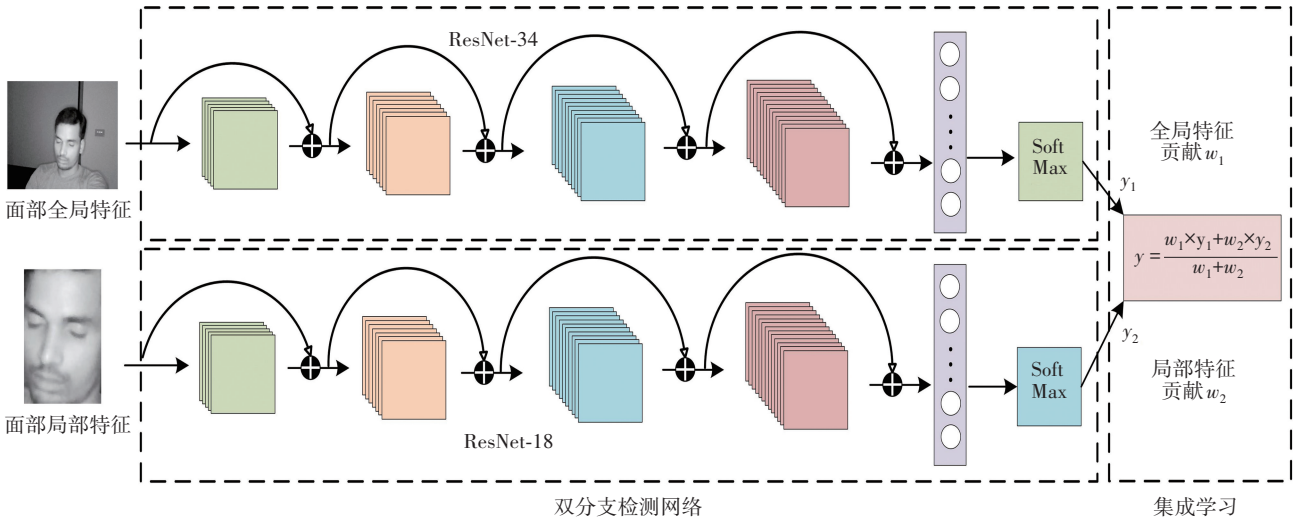

图 3 双流网络检测模块结构

Fig. 3 Structure of dual-stream network detection module

3 仿真实验与结果分析

3.1 实验设置和数据集

本实验硬件配置为 Inter i5-12400F CPU,16 GB 内存,RTX3060 显卡,使用的操作系统为 Windows。模型在 PyTorch 上进行训练和微调,低光增强模块使用自适应矩估计优化器 Adam 来优化模型,初始学习率设置为 0.002,使用学习率衰减策略,每个周期学习率降低至前一个周期的 95%,这样有助于训练的稳定和收敛。双流检测网络也使用 Adam 来优化模型,初始学习率设置为 0.001,权重衰减设置为 0.000 5,批次大小设置为 32,训练轮次设置为 100。

本文采用文献[10]的数据集进行疲劳检测,以验证模型的适用性。原始数据集包含 36 名不同种族的受试者,在不同的昼夜照明条件下模拟驾驶场景。仅使用在夜晚照明条件较差情况下的受试者数据,训练低光增强模块,训练集包含 5 206 张图像,测试集包含 1 286 张图像。针对双流网络的训练数据包含 11 298 张夜间驾驶员图像,分别按照 6∶4 的比例划分为不同

分支网络的训练集。

3.2　低光增强模块

低光增强模块基于 MBLLEN 算法改进,与原始 MBLLEN 算法相比,引入了 SE 通道注意力模块,以更加聚焦于人脸区域,从而提升增强效果。图 4 展示了这两类算法的增强效果对比。从图 4 中明显可见:MBLLEN 算法对低光图像进行的增强是全局性的,未能重点关注人脸区域,这导致驾驶员面部区域出现过度曝光,从而无法有效提取关键信息。而本文提出的改进算法更加注重人脸面部区域,增强了该区域的信息,因此能够更有效地提取关键信息。

图 4　算法对夜间图像的增强效果

Fig. 4　Enhancement effect of algorithm on night images

为了进一步验证改进算法的有效性,设计了采用两类算法提取关键信息的漏检率和图像客观评估指标的实验。漏检率指不同算法增强后的图像是否能被 MTCNN 算法检测到面部特征,图像评价指标包括峰值信噪比(PSNR)和结构相似性(SSIM)[11]。表 1 展示了两类算法的实验结果。

表 1　不同增强算法的漏检率情况和图像评价指标

Table 1　Missing detection rates and image evaluation indexes of different enhancement algorithms

算　法	图像总数	漏检率/%	峰值信噪比	结构相似性
原始图像	1 286	11.9	—	—
MBLLEN	1 286	7.70	27.831 0	0.445 6
改进的 MBLLEN	1 286	5.50	28.669 8	0.619 6

从表 1 可以看出:未处理的图像漏检率过高,而处理后的图像漏检率较低,这表明低光增强算法可以提高对面部关键特征信息的提取,而改进的 MBLLEN 算法比原始 MBLLEN 算法更加有效,对后续的疲劳检测有关键作用。同时,PSNR 和 SSIM 值越高,增强图像的质量越优。因此改进的 MBLLEN 算法对图像的增强效果更好。

3.3　双流网络检测模块

为了有效结合驾驶员面部的局部特征信息和全局特征信息,双流网络检测模块采用双分支结构,以充分利用不同分支提取的不同特征信息,进一步提高驾驶员疲劳检测的准确性。由于不同分支网络的输入数据不同,需要对单分支网络独立训练。图 5 分别展示了局部特征提取网络和全局特征提取网络的单独训练过程。

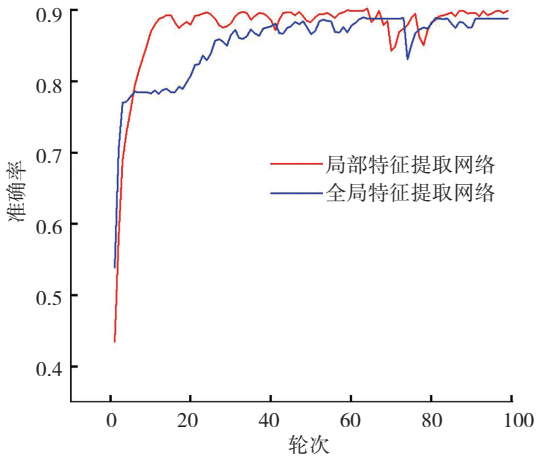

(a) 分支网络的准确率

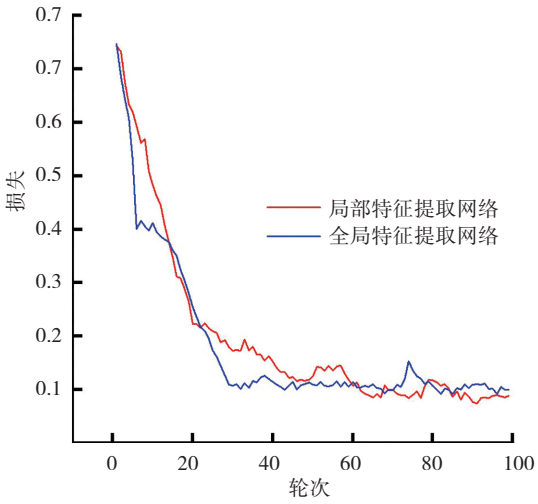

(b) 分支网络的损失

图 5　双流网络中分支网络训练过程

Fig. 5　Training process of branch networks in dual-stream network

从训练结果可以看出,各个单分支网络在 25 轮左右达到较高的准确率,最终准确率稳定在 85%~90%之间。这样的准确性表明仅依靠单一分支网络进行驾驶员疲劳检测是不完备的,因此融合不同分支网络具有

重要意义。同时,局部特征提取网络的准确率略高于全局特征提取网络,主要原因在于全局图像中包含了大量无关信息,导致网络提取过程中可能会引入噪声,从而影响网络的准确性。

为了进一步验证双流网络相比于单分支网络有性能的提升,绘制 3 种网络的 $P-R$ 曲线如图 6。从图 6 可知,双流网络的 $P-R$ 曲线覆盖面积显著大于单个分支网络,这表明融合的双流网络比各个单分支网络的检测精度高,有更好的疲劳检测效果。

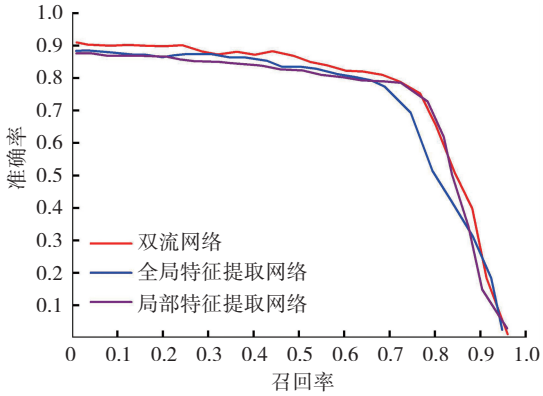

图 6 双流网络和单分支网络的 P-R 曲线

Fig. 6 P-R curves for dual-stream and single branch networks

3.4 结果与讨论

为了进一步验证低光增强模块和双流网络检测模块的有效性,设计了一系列消融实验,并将结果列于表 2 中。从表 2 可以看出:不同检测网络在应用低光增强模块后,检测精度提升了大约 3%~4%。这表明低光增强模块成功解决了夜间光线条件下难以提取驾驶员面部特征的问题,对疲劳检测效果有显著提升。此外,在相同条件下,双流网络的检测效果较单一特征提取网络提高了约 1%~2%。这结果表明双流网络能够有效融合局部特征和全局特征,对提高驾驶员疲劳检测有明显的益处。

表 2 不同模块的消融实验情况

Table 2 Ablation experiments with different modules

低光增强	局部特征提取网络	全局特征提取网络	双流网络	检测精度/%
—	✓	—	—	84.54
—	—	✓	—	84.16
—	—	—	✓	85.75
✓	✓	—	—	88.24
✓	—	✓	—	87.83
✓	—	—	✓	90.10

本文提出的驾驶员疲劳检测方法通过测试集的检测,最终得到 90.10%的驾驶员疲劳检测准确率。为了进一步验证本文所提出方法的优越性,与近年来的相关疲劳检测算法进行了比较,具体结果列在表 3 中。从表 3 可以看出:文献[13-15]使用的是传统机器学习算法,检测的准确率较低;相比之下,深度学习检测方法的准确性更优秀;文献[16]采用轻量化的神经网络算法,检测准确率达到 86.32%;文献[4][12]和本文方法均利用了全局特征和局部特征,检测的准确性优于使用单个特征的检测方法;与相关方法相比,同一场景下,本文提出的方法在疲劳检测性能方面表现出了显著的优势。

表 3 本文方法与相关检测方法的比较

Table 3 Comparison of this paper's method with related detection methods

方法	特征信息	光照条件	准确率/%
改进 Zero-DCE[4]	局部+全局	可变光照	88.80
Dlib+CNN[5]	局部	夜间低光	90.00
双流网络[12]	局部+全局	阴天低光	85.50
Dlib+模板匹配[13]	全局	夜间低光	89.34
支持向量机[14]	局部	可变光照	83.25
MLP[15]	全局	夜间低光	84.80
轻量 Zero-DCE[16]	全局	夜间低光	86.32
本文方法	局部+全局	夜间低光	**90.10**

4 结 论

本文提出一种融合局部全局特征的低光照环境驾驶员疲劳检测方法,包含低光增强模块和双流网络检测模块。低光增强模块通过改进的 MBLLEN 算法对夜间低光照情况下的驾驶员图像进行增强,从而提高了后续面部信息特征提取的效果。双流检测网络采用双分支结构,分别提取局部和全局特征信息,并通过集成学习方法权衡了这两种特征信息的贡献,显著提升了疲劳检测的准确性。实验结果表明:本文方法在夜间低光环境下对驾驶员疲劳检测的准确率达到了 90.10%。未来的研究将专注于应对夜间驾驶员佩戴眼镜等更为复杂的情况,并寻求适用的解决方法。

参考文献(References):

[1] SUN W, ZHANG X, PEETA S, et al. A real-time fatigue driving recognition method incorporating contextual features

and two fusion levels[J]. IEEE Transactions on Intelligent Transportation Systems, 2017, 18(12): 3408-3420.

[2] 王政,汪军.不同姿态下基于多特征融合的疲劳状态检测方法[J].重庆工商大学学报(自然科学版),2021,38(6):26-33.
WANG Zheng, WANG Jun. Fatigue state detection method based on multi-feature fusion under different postures[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2021, 38(6): 26-33.

[3] SHEN J, LI G, YAN W, et al. Nighttime driving safety improvement via image enhancement for driver face detection[J]. IEEE Access, 2018(6): 45625-45634.

[4] 黄振宇,陈宇韬,林定慈,等. 面向夜间疲劳驾驶检测的改进 Zero-DCE 低光增强算法[J]. 模式识别与人工智能, 2022, 35(10):893-903.
HUANG Zhen-yu, CHEN Yu-tao, LIN Ding-ci, et al. Improved Zero-DCE low-light enhancement algorithm for night fatigue driving detection[J]. Pattern Recognition and Artificial Intelligence, 2022, 35(10): 893-903.

[5] 朱艳,谢忠志,于雯,等. 低光照环境下基于面部特征点的疲劳驾驶检测技术[J]. 汽车安全与节能学报, 2022, 13(2): 282-289.
ZHU Yan, XIE Zhong-zhi, YU Wen, et al. Fatigue-driving detect-technology in low light environment based on facial feature points[J]. Journal of Automotive Safety and Energy, 2022, 13(2): 282-289.

[6] MANDAL G, BHATTACHARYA D, DE P. Real-time fast low-light vision enhancement for driver during driving at night[J]. Journal of Ambient Intelligence and Humanized Computing, 2022, 13(2): 789-798.

[7] LYU F, LU F, WU J, et al. MBLLEN: Low-light image/video enhancement using CNNs[C]//BMVC BMVA. 2018, 220 (1): 4-17.

[8] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018 (12): 7132-7141.

[9] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 770-778.

[10] WENG C H, LAI Y H, LAI S. Driver drowsiness detection via a hierarchical temporal deep belief network[C]//Lecture Notes in Computer Science. Cham: Springer International Publishing, 2017: 117-133.

[11] WANG Z, BOVIK A C, SHEIKH H R, et al. Image quality assessment: From error visibility to structural similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4): 600-612.

[12] 廖明明,赵波.基于面部表情和双流网络的驾驶员疲劳检测[J]. 科学技术与工程, 2022, 22(2): 614-619.
LIAO Ming-ming, ZHAO Bo. Driver fatigue detection based on facial expression and double-stream network[J]. Science Technology and Engineering, 2022, 22(2): 614-619.

[13] DEHANKAR V, JUMLE P, TADSE S. Design of drowsiness and yawning detection system[C]//Proceedings of the Second International Conference on Electronics and Renewable Systems. Piscataway: IEEE Press, 2023: 1585-1589.

[14] ALTAMEEM A, KUMAR A, POONIA R C, et al. Early identification and detection of driver drowsiness by hybrid machine learning[J]. IEEE Access, 2021(9): 162805-162819.

[15] GHOURABI A, GHZAOUANI H, BARHOUMI W. Driver drowsiness detection based on joint monitoring of yawning, blinking and nodding[C]//Proceedings of the IEEE 16th International Conference on Intelligent Computer Communication and Processing. Piscataway: IEEE Press, 2020: 407-414.

[16] LL Z T, JIA N, JIN H. Night fatigue driving detection algorithm based on lightweight Zero-DCE[C]//Proceedings of the IEEE 7th International Conference on Smart Cloud. Piscataway: IEEE Press, 2022: 139-144

责任编辑:李翠薇