

# 基于Yolov8算法的夜间疲劳驾驶检测研究

张 其, 马学超\*, 温鑫语, 陈雪珂, 周宇航, 邓 鑫

云南工商学院智能科学与工程学院, 云南 昆明

收稿日期: 2024年12月22日; 录用日期: 2025年1月19日; 发布日期: 2025年1月28日

## 摘 要

夜间疲劳驾驶是导致交通事故的主要原因之一, 它不仅威胁到驾驶员的安全, 也危及公共安全。在驾驶员刚发生疲劳驾驶时进行实时检测并发出预警提醒, 对于减少交通事故、保护人民生命财产具有重要意义。运用Yolov8模型对驾驶员的疲劳状态进行实时监测并做出预警, 是一种有效的解决方案。本文基于Yolov8n模型, 通过优化损失函数、增加MPDIoU来提升边界框回归精度, 并收集数据集进行训练、验证和测试。研究结果表明, Yolov8n模型在夜间疲劳驾驶检测中表现出色, 证明了Yolov8算法在夜间疲劳驾驶检测中的应用潜力。

## 关键词

疲劳驾驶, Yolov8算法, 损失函数

# Research on Night Fatigue Driving Detection Based on Yolov8 Algorithm

Qi Zhang, Xuechao Ma\*, Xinyu Wen, Xueke Chen, Yuhang Zhou, Xin Deng

School of Intelligent Science and Engineering, Yunnan Technology and Business College, Kunming Yunnan

Received: Dec. 22<sup>nd</sup>, 2024; accepted: Jan. 19<sup>th</sup>, 2025; published: Jan. 28<sup>th</sup>, 2025

## Abstract

Fatigue driving at night stands as a primary cause of traffic accidents, jeopardizing both the driver's safety and public safety. Real-time detection and immediate early warnings when drivers begin to exhibit signs of fatigue are crucial for reducing traffic accidents and safeguarding lives and property. Utilizing the YOLOv8 model for real-time monitoring and issuing early warnings for driver fatigue is an effective solution. This paper leverages the YOLOv8n model, optimizing the loss function and incorporating MPDIoU to enhance bounding box regression accuracy. Comprehensive datasets

\*通讯作者。

文章引用: 张其, 马学超, 温鑫语, 陈雪珂, 周宇航, 邓鑫. 基于Yolov8算法的夜间疲劳驾驶检测研究[J]. 计算机科学与应用, 2025, 15(1): 156-162. DOI: 10.12677/csa.2025.151016

were collected for training, validation, and testing. The results demonstrate that the YOLOv8n model excels in detecting night-time drowsy driving, affirming the potential application of the YOLOv8 algorithm in this critical area.

## Keywords

Fatigue Driving, Yolov8 Algorithm, Loss Function

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

近年来,随着社会不断发展,汽车的普及、网约车不断增加,夜间疲劳驾驶成为交通事故的主要原因之一。夜间驾驶由于光照强度低,驾驶员更容易出现疲劳现象,而检测司机是否疲劳进而做出提示可以有效保障人们的出行安全。针对疲劳驾驶的检测,目前主要依据驾驶员机体状态和汽车行驶状态特征两种方式判断。其中,以驾驶员机体状态特征为判据的检测方法又分为基于驾驶员生理状态和表观状态的检测方法。依据驾驶员的面部特征,即长时间闭眼、瞌睡、打哈欠等各种指标来判断驾驶员是否疲劳。而计算机视觉和深度学习技术作为疲劳驾驶检测方法逐渐兴起并成为研究热点[1]。

疲劳驾驶检测在深度学习的推动下取得了突破性进展。基于深度学习的目标检测方法通常可以分为单阶段和两阶段两种类型以及卷积神经网络(CNN)方法。YOLO (you only look once)是代表性的单阶段目标检测算法。YOLO 算法将目标检测问题转化为一个回归问题,通过将图像划分为网格单元并在每个单元中预测边界框的类别和位置。单阶段目标检测算法的优点为速度快,适用于实时应用,算法结构相对简单,易于理解和实现[2]。在夜间环境下,由于光照强度较低,传统的疲劳检测算法难以有效准确进行检测。Yolov8 算法凭借其强大的泛化能力、快速的检测速度和高准确度能有效解决这一问题。并且,Yolov8 模型结合机器视觉技术,在疲劳驾驶检测与预警系统研究中展现出巨大的潜力。这对于提高交通安全、减少交通事故具有重要的实际意义。随着技术的不断进步,该领域的研究和应用前景将更加广阔。

## 2. Yolov8 算法

Yolo (you only look once)算法最早由华盛顿大学的 Joseph Redmon 和 Ali Farhadi 于 2015 年开发的流行目标检测和图像分割模型,并随后进行了多次改进和迭代,产生了一系列不同版本的 Yolo 模型。Yolov8 作为一种 SOTA (State-of-the-Art)模型,构建在 Yolo 系列的基础之上,融合了先前经验,同时引入了创新性的特性和改进,以进一步提高其性能和灵活性,使其成为目标检测、图像分割、姿态估计等多项任务的首选。

### 2.1. Yolov8n 网络模型结构

Yolov8n 网络结构分为三部分: Backbone 主干网络,用于特征提取; Neck 进行特征融合网络; Head 检测头,进行解码。其中,特征提取网络采用的是 CSP-Darknet53,它包括一系列卷积层和残差块,可以从输入图像中提取出高层次的特征。特征融合网络包括一些卷积层和上采样层,用于将不同分辨率的特征图进行融合,以便更好地适应不同尺度的目标。最后,检测头包括一系列卷积层和最终的输出层,用于对检测框的位置和类别进行预测[2]。Yolov8 的网络结构延用了 Yolov5 的网络结构思想,包括基于 CSP

(紧凑和分离)的骨干网络(backbone)和 Neck 部分的设计, 以及对于不同尺度模型的考虑。其结构如图 1 所示:

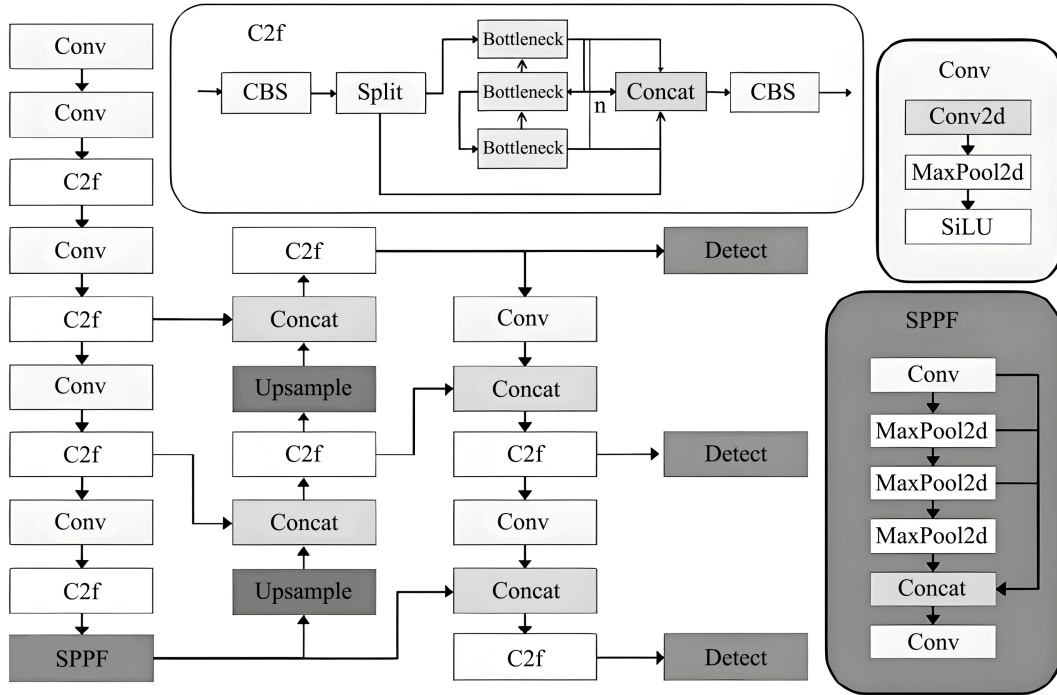


Figure 1. Yolov8n network structure model [3]

图 1. Yolov8n 网络结构模型[3]

## 2.2. 损失函数

Yolov8 的损失函数由多个部分组成, 包括分类损失(VFL Loss)、回归损失为 CIoU Loss + DFL 的形式。对损失函数进行改进[4], 增加 MPDIoU 提升边界框回归精度。预测框  $B_{prd}$  和真实框  $B_{gt}$  的边界框坐标。  $B_{prd} = (x_1^{prd}, y_1^{prd}, x_2^{prd}, y_2^{prd})$   $B_{gt} = (x_1^{gt}, y_1^{gt}, x_2^{gt}, y_2^{gt})$ , 输入图像的宽度  $w$  和高度  $h$ , 对于预测框  $B_{prd}$ , 确保  $x_2^{prd} > x_1^{prd}$  和  $y_2^{prd} > y_1^{prd}$ 。

$$d_1^2 = (x_1^{prd} - x_1^{gt})^2 + (y_1^{prd} - y_1^{gt})^2 \quad (1)$$

$$d_2^2 = (x_2^{prd} - x_2^{gt})^2 + (y_2^{prd} - y_2^{gt})^2 \quad (2)$$

$$\text{计算 } B_{gt} \text{ 的面积: } A^{gt} = (x_2^{gt} - x_1^{gt}) \times (y_2^{gt} - y_1^{gt}) \quad (3)$$

$$\text{计算 } B_{prd} \text{ 的面积: } A^{prd} = (x_2^{prd} - x_1^{prd}) \times (y_2^{prd} - y_1^{prd}) \quad (4)$$

计算  $B_{prd}$  和  $B_{gt}$  之间的交集  $I$ :

$$x_1^I = \max(x_1^{prd}, x_1^{gt}), \quad x_2^I = \min(x_1^{prd}, x_1^{gt}) \quad (5)$$

$$y_1^I = \max(y_1^{prd}, y_1^{gt}), \quad y_2^I = \min(y_1^{prd}, y_1^{gt}) \quad (6)$$

$$I = \begin{cases} x_2^I - x_1^I \times y_2^I - y_1^I & \text{当 } x_2^I > x_1^I, y_2^I > y_1^I \\ 0 & \text{其它} \end{cases} \quad (7)$$

$$\text{计算交并比: } \text{IoU} = \frac{I}{A^{gt} + A^{prd} - I}, \text{ 改进的交并比: } \text{MPDIoU} = \text{IoU} - \frac{d_1^2}{h^2 + w^2} - \frac{d_2^2}{h^2 + w^2} \quad (8)$$

$$\text{IoU 损失: } L_{\text{IoU}} = 1 - \text{IoU}, \text{ MPDIoU 损失: } L_{\text{MPDIoU}} = 1 - \text{MPDIoU} \quad (9)$$

### 3. 图像数据采集和标注

在本次实验中,采集夜间人脸疲劳包括闭眼、打哈欠、低头和正常状态的数据集 800 张。比例按照 9:1 随机划分为训练集、验证集两部分,分别为 720 幅、80 幅,使用 Labelimg 对数据集进行标注,并从测试集随机挑选 10 张进行模型测试。

## 4. 实验

### 4.1. 实验环境和方法

本次实验训练配置及参数设定:处理器为英特尔酷睿™ i7, GPU 为 NVIDIA GeForce RTX 4060, 显存为 8.0 GB, 操作系统为 Windows 10, 使用 Python 版本为 3.8.10, CUDA 版本为 11.7, 使用 Pytorch 框架进行训练, torch 版本为 1.13.1, 迭代次数 Epoch 设为 100 [5], 批次大小设为 16, 图像输入尺寸为 640 像素 × 640 像素。

### 4.2. 实验结果

如图 2 指标变化图,训练和验证过程中的边界框回归、分类、分布式交点损失变化,模型的精度、召回率(recall)和平均精度(mAP)等指标随迭代次数增加变化的曲线图。

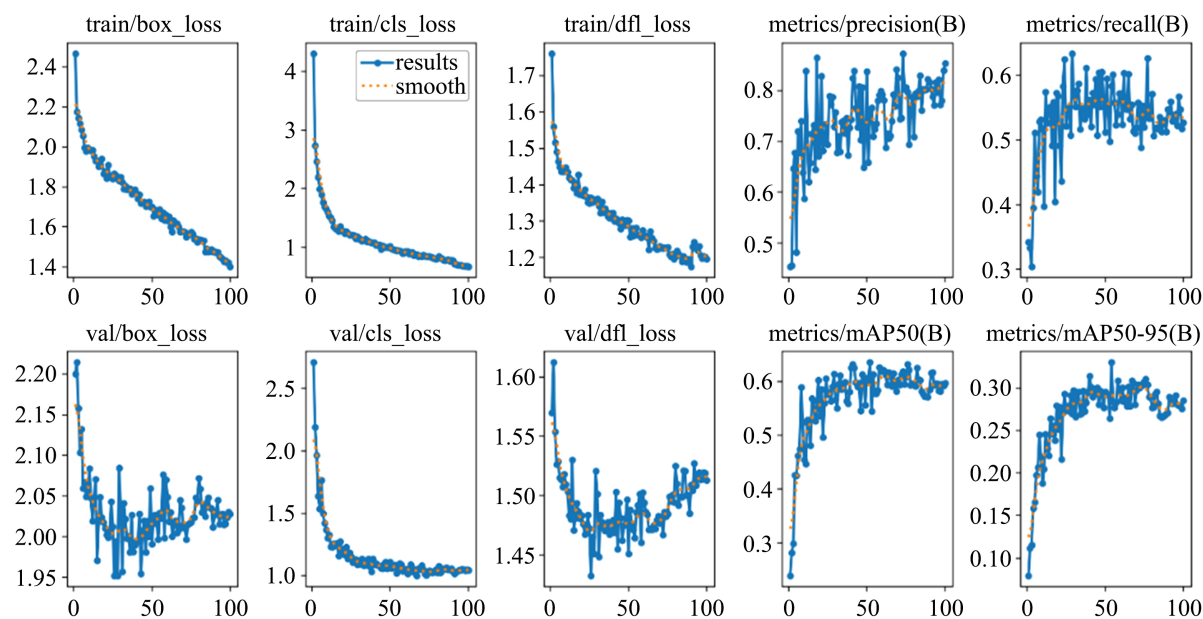


Figure 2. Indicator trend chart

图 2. 指标变化图

当迭代次数趋于 100 次时,模式的各类损失值逐渐减小并趋于稳定,说明训练迭代过程中,模型的性能在不断改善。根据 metrics/precision(B)观测模型正确预测的正样本占有所有预测为正样本的比例为 82%,显示出较高的精确度。此外,由 metrics/mAP50(B)观测在 IoU 阈值为 0.5 时的平均精度为 0.62。表明模型

在该特定条件下能够较好地地区分目标与非目标。由 metrics/mAP50-95(B)观测在 IoU 阈值从 0.5 到 0.95 (步长为 0.05)的平均精度为 0.28。Yolov8 在夜间疲劳驾驶检测中虽然会降低检测准确度，但在调整损失函数后，Yolov8 模型趋于稳定，可应用在夜间疲劳驾驶检测。




Figure 3. Precision-recall curve  
图 3. Precision-recall 曲线图




Figure 4. F1-confidence curve  
图 4. F1-confidence 曲线图

通过图 3 Precision-Recall 曲线图分析, 所有类别在 IoU 阈值为 0.5 时平均精度为 0.614, 模型表现性能良好。对于 ceye-fatigue、omouth-fatigue、normal 类别检测中, 模型性能较好, 其平均精度 AP 值为 0.867、0.740、0.843, 在识别 ceye-fatigue、omouth-fatigue、normal 类别时具有较高的准确性和召回率。在 bhead-fatigue 和 cmouth-fatigue 类别识别中性能表现中规中矩。而对于 teye-fatigue 类别的模型性能表现较差, 其 AP 值较低仅为 0.028, 表明在识别 teye-fatigue 类别时存在一定难度, 需要进一步优化或训练更多数据来提高性能。通过进一步分析图 4 的 F1-Confidence 曲线图, 可以观测到不同类别在不同置信度阈值下的 F1 分数表现。所有类别的平均 F1 分数为 0.56, 对应的最佳置信度阈值为 0.287。表明当置信度阈值设置为 0.287 时, 所有类别的平均 F1 分数达到最高。因此, 在实际应用决策中, 可依据这个平衡点, 使得模型在保持较高准确性的同时, 也能减少误判。

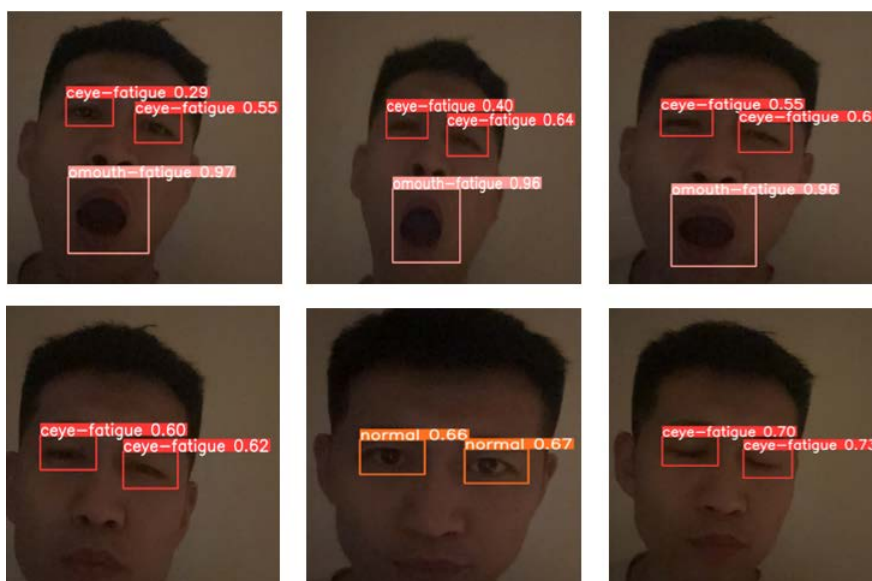


Figure 5. Detection effect diagram  
图 5. 检测效果图

通过图 5 检测效果图分析, 眼睛疲劳(eye-fatigue)的检测结果, 置信度得分从 0.29 到 0.73, 当分数越高时, 表明模型检测眼睛处于疲劳状态的置信度高。嘴巴疲劳(mouth-fatigue)检测结果置信度得分从 0.96 到 0.97, 表明模型对嘴巴疲劳状态的置信度非常高。对于正常状态监测(normal), 依据眼睛的检测结果, 得分分别为 0.66 和 0.67, 表明模型对正常状态的检测置信度较高。依据上述分析, 模型对疲劳状态的置信度范围从 0.29 到 0.97, 而对正常状态的置信度在 0.66 到 0.67 之间。这表明模型在检测疲劳状态时具有较高的准确性, 尤其是在眼睛和嘴巴疲劳的检测上。

## 5. 结语

本文应用 Yolov8 算法验证夜间疲劳驾驶检测效果, 训练模型在 ceye-fatigue、omouth-fatigue、normal 类别检测中表现性能较好。由于夜间光照条件差, 模型在 teye-fatigue 类别中检测性能一般。实验表明 Yolov8 算法可以应用在夜间疲劳驾驶中检测场景下, 而在未来可通过改进的图像增强技术、优化的网络结构设计或特定的损失函数, 进一步优化、改进模型, 以提高在低光照条件下的检测性能。因此, Yolov8 算法模型具备用于实际场景中进行全天候疲劳驾驶监测方面的潜力, 通过精确地检测和分类驾驶员的疲

劳状态, 可以实时提醒驾驶员疲劳状态, 从而降低因疲劳驾驶导致的事故风险。此外, 该模型还可以与其他交通安全技术相结合, 如自动驾驶系统、车辆碰撞预警等, 共同构建一个更加安全的道路交通环境。

## 基金项目

云南工商学院本科生研究基金: YGSBKSKY2023034。

## 参考文献

- [1] 马若寒. 基于深度学习的移动目标视觉跟踪及应用研究[D]: [硕士学位论文]. 天津: 天津大学, 2020.
- [2] 郑凯东, 舒心. 基于 BFDS 改进的 YOLOv8 疲劳驾驶检测算法[J]. 信息技术与信息化, 2024(2): 213-216.
- [3] 何宗熹, 蒋明忠. 基于 YOLOv8 和人脸关键点检测的驾驶员疲劳驾驶识别算法设计[J]. 电脑与电信, 2023(11): 1-6, 13.
- [4] CSDN. YOLOv8 损失函数改进-增加 MPDIoU 提升边界框回归精度[EB/OL]. [https://blog.csdn.net/Dora\\_blank/article/details/140386628](https://blog.csdn.net/Dora_blank/article/details/140386628), 2024-09-17.
- [5] 李真, 高莉. 基于 YOLOv5-CC 的驾驶员疲劳状态检测[J]. 江苏师范大学学报(自然科学版), 2024, 42(1): 72-76.