

DOI: 10.13718/j.cnki.xdzk.2025.08.004

潘健东, 范超杰, 姜卓希, 等. 基于 YOLOv8 的驾驶员分心行为实时检测研究 [J]. 西南大学学报(自然科学版), 2025, 47(8): 38-48.

基于 YOLOv8 的驾驶员分心行为实时检测研究

潘健东, 范超杰, 姜卓希, 邓涵文, 伍贤辉, 彭勇

中南大学 交通运输工程学院, 长沙 410075

摘要: 分心驾驶行为会加大交通事故发生概率, 威胁到驾驶员生命安全。针对现有公开驾驶分心行为数据普遍缺乏职业驾驶员群体的不足, 构建了面向职业驾驶员群体的分心驾驶行为数据集。YOLO 模型凭借其快速的检测性能, 在实时目标检测领域得到广泛应用。构建了一种基于 YOLOv8 的分心驾驶行为检测算法。首先, 将 CBAM 注意力机制集成进 YOLOv8n 主干网络中, 增强模型的全局特征提取能力。其次, 在颈部网络中, 将 FasterBlock 模块与 C2f 模块融合, 形成 C2f-FasterBlock 模块, 并集成于 YOLOv8 模型中。在自建的驾驶场景数据集的实验结果表明, 改进的 YOLOv8n 算法显著提高了分心驾驶行为检测精度, 平均精度比原本的 YOLOv8n 高出 4.88%。

关键词: 职业驾驶员分心行为数据集; YOLOv8; 分心驾驶;

深度学习

中图分类号: TP183; TP391.4; U492.8

文献标识码: A

开放科学(资源服务)标识码(OSID):



文章编号: 1673-9868(2025)08-0038-11

Real-Time Detection of Driver Distraction Behavior Based on YOLOv8

PAN Jiandong, FAN Chaojie, JIANG Zhuoxi,
DENG Hanwen, WU Xianhui, PENG Yong

School of Traffic & Transportation Engineering, Central South University, Changsha 410075, China

Abstract: Distracted driving behavior increases the probability of traffic accidents and threatens drivers' safety. To address the lack of professional driver groups in existing public driving distraction behavior datasets, this study constructs a distracted driving behavior dataset specifically targeting professional driv-

收稿日期: 2025-04-23

基金项目: 国家自然科学基金项目(U24B20123); 湖南省科技创新计划项目(2022RC3044)。

作者简介: 潘健东, 硕士研究生, 主要从事机器视觉与深度学习研究。

ers. The YOLO model has gained widespread application in real-time object detection due to its rapid detection capabilities. This paper develops an improved distracted driving detection algorithm based on YOLOv8. Firstly, the Convolutional Block Attention Module attention mechanism was integrated into the backbone network of YOLOv8n to enhance the model's global feature extraction capability. Secondly, in the neck network, the FasterBlock module was combined with the C2f module to form a C2f-FasterBlock module, which was subsequently integrated into the YOLOv8 architecture. Experimental results with our self-built driving scenario dataset demonstrate that the enhanced YOLOv8n algorithm significantly improved detection accuracy for distracted driving behaviors, achieving a 4.88% higher mean average precision compared to the original YOLOv8n model.

Key words: professional driver distraction behavior dataset; YOLOv8; distracted driving; deep learning

分心驾驶行为是指驾驶员将驾驶资源从对安全驾驶至关重要的任务转移到与之竞争的次任务上^[1], 这种资源分配失衡会影响驾驶绩效^[2], 最终威胁到行车安全。驾驶绩效的核心资源依赖视觉注意力与中枢神经处理的协同机制。当驾驶员进行驾驶次任务(如操作手机)时, 会触发双重干扰效应: 视觉干扰通过转移视线焦点造成目视监测中断; 认知干扰通过占用大脑核心运算资源削弱驾驶决策能力^[3], 从而提高遇到风险场景时决策反应时间, 增加事故发生概率^[4]。根据美国国家公路交通管理局 2023 年公布的最新数据显示, 2021 年涉及分心驾驶的交通事故共造成 3 522 人死亡, 较 2020 年增加了 12.1%^[5]。因此实时监测驾驶员驾驶状态, 并对检测到的分心驾驶行为给予必要的预警, 对保障行车安全具有重要意义。

为降低因驾驶员因素而导致事故发生率, 相关领域的研究学者们对驾驶员监管系统(Driver Monitor System, DMS)展开了深入研究。DMS 系统主要功能是检测驾驶员在执行驾驶任务时是否呈现异常状态, 并在检测到分心状态时及时发出警告予以纠正^[6]。而在分心检测任务中, 常用的检测算法有 YOLO 系列算法、ResNet 与 AlexNet 等改进型卷积神经网络等^[7]。根据获取信息特征可分为两类: 驾驶人生理信号和驾驶风格特征。其中, 关于驾驶风格研究, 主要通过分析外部传感器采集到的平均车速、横向加速度标准差、方向盘转速等信息进行驾驶员状态分析^[8], 该方法虽能够识别驾驶员状态, 但识别效果容易受天气、道路状况等客观因素影响^[9]; 关于驾驶员生理信号研究, 根据生理信号获取方式可分为侵入式和非侵入式两类^[7]。侵入式是指通过智能手环、脑电帽等传感器进行持续、稳定的人机接触方式, 获取生理信号^[10]。此种方法虽然识别准确率高, 但在一定程度上影响驾驶员安全驾驶能力, 因此更适用于实验研究和数据采集场合。非侵入式借助计算机视觉技术与深度学习实现, 通过车载摄像头实时收集驾驶员面部特征、头部姿态特征、动作行为特征等个体信息与标定物品(手机、水瓶等影响安全驾驶物品), 并通过深度学习技术识别驾驶员动作和行为。此种方法成本低、准确率较高, 不影响驾驶员安全驾驶, 更适用于监控驾驶员^[11-12]。

随着深度学习目标检测算法的多次迭代更新, 以 YOLO(You Only Look Once)^[13]系列为代表的实时目标检测算法, 广泛应用于目标识别领域中。目前 Ultralytics 公司推出的 YOLOv11 是 YOLO 系列目标检测算法的最新成果, 在目标检测领域展现更加强大的性能^[14]。而除了目标检测外, YOLO 系列算法在姿态估计领域也发挥着举足轻重的作用^[15]。因此越来越多的驾驶员状态检测方法选择了 YOLO 系列算法: 为解决环境因素(光照、遮挡)导致的驾驶员检测精度低、误检等问题, 文献[16]将 Swin Transformer 编码器、RepGFPN 聚合网络等融合进 YOLO-Pose, 经实验测试, 在复杂场景下仍能保持较高精度和鲁棒性; 为提高模型在复杂场景下的识别准确性, 文献[17]对 YOLOv8 颈部网络和 SPPF 模块进行改进, 并集成全

局注意力机制, 增强 YOLO 算法在多尺度特征提取能力; 文献[18]提出了一种多模态特征融合方法结合粒子群算法获取特征权重, 通过捕捉时间依赖性, 增强模型获取特征能力。

目前, 深度学习在驾驶员分心行为检测方面取得重大进展, 然而将现有的大部分研究成果应用在职业驾驶员群体上, 会表现出明显的性能下降。这是因为大部分研究成果是基于普通驾驶员数据集训练得出, 而职业驾驶员和普通驾驶员之间驾驶行为具有显著差异, 进而产生跨领域适应问题^[19], 这会影响它们在职 业驾驶员群体的应用。为了解决这些问题, 本研究重新构建面向职业驾驶员群体的分心驾驶行为数据集。在 YOLO 模型选择上, 为满足研究场景速度快、检测精度高的特点, 选择参数量最小、检测速度最快的 YOLOv8n 作为本研究的基础模型。综上, 本研究主要贡献包括:

- 1) 构建了一个专门面向职业驾驶员群体的分心驾驶行为数据集。该数据集从 99 名职业驾驶员日常驾驶过程中采集视频片段 7 886 条, 累计时长约 44 h, 包含喝水、摄食、吸烟和使用手机 4 类典型分心行为, 为后续分心驾驶行为识别研究提供了丰富、真实的数据基础。
- 2) 提出了一种基于 YOLOv8 的非接触式驾驶员分心驾驶行为检测方法。针对 YOLOv8 在多尺度特征提取能力不足以及检测速度较慢的问题, 引入了卷积注意力模块(Convolutional Block Attention Module, CBAM)^[20]与快速块模块(FasterBlock)^[21], 对网络结构进行优化改进。实验结果表明, 该方法有效提升了模型在职业驾驶员分心行为识别任务中的检测精度与实时性, 同时具备无侵入、易部署等优势, 更符合实际驾驶环境下的应用需求。

1 分心驾驶行为数据集

1.1 数据集描述

现有的分心驾驶行为数据集(如 100-Driver 数据集^[22]、SFDDD 数据集^[23]、QIN 数据集^[17]等)实验参与者群体未集中于职业驾驶员群体。研究表明非职业驾驶员驾驶习惯、驾驶风格等都与职业驾驶员有着显著差异, 可能会导致模型在职业驾驶场景下的泛化性能下降^[19]。为填补这一不足, 我们重新构建一个面向职业驾驶员的分心驾驶行为数据集, 在实验开始前, 已从被试者获得关于本研究数据使用的知情同意。

- 1) 数据采集。使用两个海康威视摄像头收集分心驾驶行为数据。为确保采集数据角度的多样性, 选择了两个角度, 分别是左前方、右上方, 多角度视图能够提供驾驶员出现分心行为时的全面视图, 并且可用于后续评估模型对不同未知摄像头的泛化能力。用于收集分心驾驶行为的摄像头数量及具体安装位置如图 1 所示。
- 2) 参与实验群体特征。共招募 99 名持有 C1 驾驶证人员参与驾驶行为数据采集实验。样本群体按职业性质可分为出租车驾驶员、网约车驾驶员。其中出租车驾驶员 93 名, 网约车驾驶员 6 名, 如图 2 所示。



图 1 数据采集摄像头位置示意




图 2 参与实验志愿者职业分布

3) 职业驾驶员行为风格多样化。前面提到与非职业驾驶员相比,职业驾驶员驾驶风格、驾驶行为等都有着显著差异,为丰富数据集的驾驶行为,受邀参加实验的 99 名实验人员有着不同的年龄及职业驾龄,具体情况如图 3 所示。




图 3 志愿者年龄、性别及职业驾龄分布

4) 环境因素。为了采集到的数据尽可能涵盖不同的驾驶环境,我们将被试者分成昼间组和夜间组,其中:昼间组共 50 名受试者,在 9:00—15:00 时段连续采集 12 d 数据;夜间组共 49 名被试者,在 18:00—3:00 时段连续采集 8 d 数据,涵盖了黄昏、夜间等不同光照条件。同时,涵盖了穿越隧道、早晚高峰期等不同驾驶环境,以此保证数据的全面性。

1.2 数据处理

本研究计划构造的分心驾驶行为数据集划分为 4 个主要类别:摄食、吸烟、使用手机及饮水。基于此,本次实验共收集视频片段共 7 886 段。其中摄食 962 段、吸烟 704 段、使用手机 5 517 段、饮水 703 段,如图 4 所示。

由于实验采集到的是视频数据,为满足模型训练需要,需要从视频进行抽帧完成原始数据集制作。考虑到在连续动作过程中相邻帧之间相似度较高,若不从数据集里将相似帧筛选出,则会降低数据集样本的多样性,进而影响模型的泛化能力。

为尽可能保证数据之间存在较大差异,采取每 2 s 从视频片段抽取一帧的采集策略,获取了 46 110 张图片,并从中手动筛选出 11 515 张,完成数据集构建(示例图片见图 5)。完成数据的筛选后的数据集规模如表 1 所示。




图 4 4 类分心驾驶行为视频片段数量统计图

表 1 职业驾驶员分心驾驶行为数据集张

摄食	吸烟	使用手机	饮水	共计
1 428	1 010	8 100	977	11 515

从表 1 不难发现,使用手机规模占比最大,占比约为 70.34%,主要原因在于智能手机会使人上瘾,促

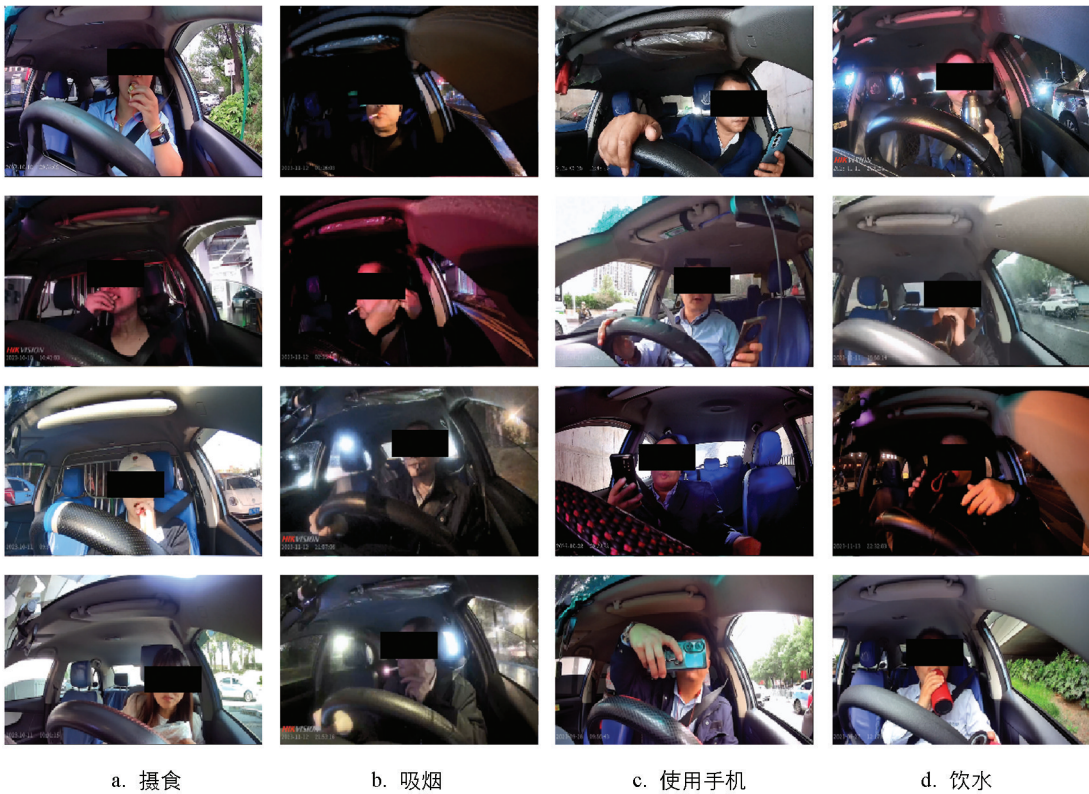


图 5 职业驾驶员分心驾驶行为数据集示例

使用户产生与智能手机保持连接状态的情感需求^[24],进而将大量时间消耗在智能手机上。然而使用手机数据占比过大容易导致训练模型过度关注此类分心行为,进而导致其他类别检测性能下降。因此为保证训练模型性能,需要平衡驾驶分心行为规模,通过随机抽选方式,抽取使用手机数据规模约 1/5 构建数据集、从 100-Driver^[22]随机抽取吸烟和饮水的分心行为数据进行补充。表 2 展示本实验构建的分心驾驶行为数据集训练集、验证集和测试集的组成情况。

表 2 分心驾驶行为数据集分类统计

张

类别	训练集	验证集	测试集
摄食	1 000	286	142
吸烟	1 007	202	101
使用手机	1 134	324	162
饮水	984	195	98
共计	4 125	1 007	503

1.3 数据集对比

由于分心驾驶行为会受到个人驾驶习惯的影响而表现出显著差异,检测驾驶员分心驾驶行为仍是个艰巨挑战,而现有的分心驾驶行为数据集多聚焦于普通驾驶员人群,尚缺乏专门面向职业驾驶员群体的高质量数据集。据我们所知,目前没有专门的数据集聚焦于职业驾驶员人群。因此我们的数据集具有以下显著优势:首先,所有数据均来源于职业驾驶员群体,更贴近真实运营场景。其次,参与实验的职业驾驶员人数远超大部分数据集,在人数规模上仅次于目前最大的 100-Driver 数据集^[22]。表 3 对本数据集与现有节选数据集进行了详细对比。

表 3 驾驶分心行为数据集比对

数据集	分型行为种类/种	标注样本总量/个	实验人群职业	志愿者数量/个
SFDDD 数据集 ^[23]	10	28 991	普通驾驶员	25
QIN 数据集 ^[17]	6	52 461	普通驾驶员	6
100-Driver 数据集 ^[22]	21	470 208	普通驾驶员与职业驾驶员	100
定制数据集 ^[25]	4	6 400	普通驾驶员	16
本研究数据集	4	5 635	职业驾驶员	99

2 驾驶员分心行为检测方法

2.1 基于改进 YOLOv8n 的分心驾驶行为检测模型

为适应驾驶员分心驾驶行为快速识别需求，要求模型速度推理速度快，因此选择 YOLOv8 系列中参数量最少且检测速度最快的 YOLOv8n 作为本研究基础模型。YOLOv8 系列模型在 COCO 数据集展现了优越的性能，但是它在具有“快速、复杂、多变”的分心驾驶行为检测任务中仍存在以下问题^[17]：

- 1) YOLOv8 主干网络缺乏有效的全局信息集成模块。虽然作者通过跨阶段局部网络(Cross Stage Partial Network, CSP)架构和两层卷积跨阶段部分连接模块(CSP Bottleneck with 2 Convolutions, C2f)增强局部特征提取能力，但是全局信息能力的缺失，可能会降低模型有效捕捉多尺度分心驾驶行为的能力。
- 2) YOLOv8 颈部网络在进行空间通道特征融合时，引入过多冗余信息，进而影响模型检测速度。
- 针对以上问题，对主干网络和颈部网络进行改进，改进后结构如图 6 所示。




图 6 改进后的 YOLOv8 模型结构

2.2 融合 CBAM 的主干网络

为增强 YOLOv8 对提取全局特征的总和能力，我们在空间金字塔池化(Spatial Pyramid Pooling Fast, SPPF)模块之前引入 CBAM。CBAM^[20]由通道注意力模块和空间注意力模块两个子模块构成。两个子模块

通常串联使用: 通道注意力模块对每个通道输入的特征进行加权处理, 突出关键特征; 之后空间注意力模块丰富其空间位置的关键信息。此过程同时考虑通道和空间信息, 有助于网络更有针对性地关注重要特征。CBAM 结构如图 7 所示。




图 7 CBAM 结构

2.3 C2f-FasterBlock 模块

为克服颈部网络检测速度慢的问题, 引入 FasterBlock, 该模块能够以较低的浮点运算量实现较高的模型性能, 体现出良好的轻量化效果^[21], 具体结构如图 8 所示。作者在该模块中提出一种部分卷积的新运算符 (Partial Convolution, PConv), 该卷积核能够使所在的 FasterBlock 具备速度快且参数少的优点。同时, 内置的批量归一化模块 (Batch Normalization, BN) 能够允许 FasterBlock 与相邻的卷积核模块结合, 进而加快推理速度。具体工作原理如下: FasterBlock 在保持通道数不变的情况下, 仅对输入特征中的一部分通道执行 $k \times k$ 常规卷积操作, 余下通道则直接在 1×1 卷积中与卷积结果融合。PConv 的每秒完成浮点运算次数 (Floating Point Operations per Second, FLOPs) 值为:

$$f_{\text{Fast}} = h \times w \times k^2 \times C_p^2 \tag{1}$$

式中: f_{Fast} 表示 FasterBlock 模块的总浮点运算次数; h 、 w 分别为输入通道空间尺寸高、宽; k 为滤波器卷积核尺寸 (此处高、宽相等, 因此统一变量为 k); C_p 为参与卷积操作的通道数。




图 8 FasterBlock 结构

公式(1)适用于仅对 C_p 通道执行卷积,且输出通道数也为 C_p 的场景。若卷积层完整输出 C 个通道,其中仅有 C_p 个通道参与卷积运算,则 C_p 和 C 共同构成的分离比定义为:

$$r = \frac{C_p}{C} (0 < r \leq 1) \quad (2)$$

式中: r 值代表被过滤器卷积的通道占比。

当 $r = \frac{1}{4}$ 时, PConv 的 FLOPs 值只有普通卷积的 $\frac{1}{16}$, 并且 PConv 内存访问量达到最小值, 其近似表达式为:

$$h \times w \times 2C_p + k^2 \times C_p^2 \approx h \times w \times 2C_p \quad (3)$$

因此, 本文使用 FasterBlock 替换 YOLOv8 颈部网络的 C2f 模块中的瓶颈模块(Bottleneck), 得到 C2f-FasterBlock。

3 模型性能评估

3.1 试验模型评价指标

本研究定义的分心驾驶行为检测任务包括对象检测和分类两方面, 同时将关注重点放在评估模型在测试集上的准确性。基于此, 采用 5 个指标: 准确率(Precision, P)、平均精度(mean Average Precision, mAP)、预测边界框与真实边界框交并比达到 0.5 时的总类平均值(mean Average Precision@0.5%, $mAP@0.5\%$)、召回率(Recall, R)和 F1 值(F1 Score, $F1$)。

各指标的定义如下所示, 其中 n 为本文定义的驾驶分心行为的类别数量:

$$P = \frac{TP}{TP + FP} \times 100\% \quad (4)$$

$$mAP = \frac{1}{n} \sum_{i=0}^n AP(i) \quad (5)$$

$$R = \frac{TP}{TP + FN} \times 100\% \quad (6)$$

$$F1 = 2 \times \frac{P \times R}{P + R} \quad (7)$$

式中: TP 表示实际为正样本, 且被模型正确预测为正样本的数量; FP 表示实际为负样本, 但被模型错误预测为正样本的数量; FN 表示实际为正样本, 但被模型错误预测为负样本的数量; n 是分心类别的总数; AP 表示单个分心类型的检测精度

3.2 模型性能分析

本研究以 YOLOv8n 为基准模型, 分别使用 YOLOv8n 模型和本研究改进的模型, 在本研究新构建的分心驾驶行为数据集中进行实验, 本研究模型与 YOLOv8n 相比, 在定义的 4 种分心驾驶行为类别上, 在所有类别上的检测精度都有所提升。具体来说, “摄食”行为检测精度提升了 3.53%、“吸烟”行为检测精度提升了 5.96%、“使用手机”行为检测精度提升了 4.92%、“饮水”行为检测精度提升了 5.1%, 效果如表 4 所示。

改进模型召回率和 F1 值都有所提升, 表明模型在对定义的分心驾驶行为保持较高检测精度的同时, 减少了漏检情况的发生, 对分心驾驶行为的整体识别能力有所增强。

值得注意的是, 在定义的 4 种分心驾驶行为中, “摄食”“吸烟”“饮水”具有相似的检测精度且都低于“使用手机”检测精度。可能原因在于驾驶员在使用手机时, 通常涉及明显的手部动作, 如持握、滑动等操作, 且手机在被使用时, 常位于驾驶员正前方, 靠近摄像头, 具备清晰的外观特征和有利的拍摄角度, 有助于模型识别。而另外 3 类分心驾驶行为, 都具有相似的手部动作: 即将物体送入口中, 动作模式上高度相

似, 且相关物体常因距离较远, 模型难以准确捕捉特征, 进而导致识别难度较高, 检测精度相对较低且差异不大, 行为动作如图 9 所示。

综上所述, 根据表 4 实验结果, 所提出的改进模型在职业驾驶员分心驾驶行为识别任务中展现出较好的性能表现, 具有一定的实用参考价值。

表 4 模型对比实验

模型	检测精度/%				mAP /	$mAP@0.5$ /	R /	$F1$ /
	摄食	吸烟	使用手机	饮水	%	%	%	%
YOLOv8n	80.98	78.2	86.42	78.57	81.04	85.38	77.55	81.28
本研究模型	84.51	84.16	91.34	83.67	85.92	90.16	78.52	83.94



图 9 驾驶分心行为检测效果图

为评估各改进模块的贡献, 在保持运行环境一致的前提下进行消融实验。如表 5 所示, $\checkmark$ 表示使用相应的改进模块; g 表示模型对单张图像推理所需的浮点运算总量, 以十亿次为单位 (Giga FLOPs, GFLOPs); p 表示模型总参数量, 以百万字节 (Million Bytes, MB) 为单位, 反映模型的复杂度。

以 YOLOv8n 为基准模型, 得到原始 $mAP@0.5$ 为 85.38%, 参数量 p 为 3、推理计算量 g 为 8.2。在此基准上, 单独引入 CBAM, $mAP@0.5$ 提升至 87.13%, 计算量基本不变; 引入 C2f-FasterBlock, $mAP@0.5$ 提高到 88.71%, 同时将 g 和 p 分别降至 7.1 和 2.5, 体现出明显的轻量化优势。最后将两模块集成进行实验, $mAP@0.5$ 进一步提升至 90.16%, 尽管 g 和 p 小幅回升, 但整体检测精度优于基准值, 验证了本文改进策略的有效性。

表 5 消融实验

YOLOv8n	CBAM	C2f-FasterBlock	$mAP@0.5$ /%	g /G	p /MB
$\checkmark$			85.38	8.2	3.0
$\checkmark$	$\checkmark$		87.13	8.3	3.1
$\checkmark$		$\checkmark$	88.71	7.1	2.5
$\checkmark$	$\checkmark$	$\checkmark$	90.16	8.9	3.1

4 结论

本研究针对现有分心驾驶行为数据集数据未涵盖职业驾驶员群体特点,构建以职业驾驶员群体为主的分心驾驶行为数据集。同时针对 YOLOv8 局限性,进行针对性的改进,提高了算法对驾驶员分心驾驶行为的识别精度与检测速度。具体改进包括将 CBAM 融合进主干网络以及用 FasterBlock 替换颈部网络 C2f 模块中的残差块。实验结果表明,改进后的模型检测性能得到有效提升。

但值得注意的是,与文献[17, 22-23]相比,改进后检测准确率仍有较大提升空间,主要原因在于本研究所构建的数据集规模较小:约为 SFDDD 数据集^[23]的 $\frac{1}{5}$;约为 QIN 数据集^[17]的 $\frac{1}{9}$;约为 100-Driver 数据集^[22]的 $\frac{1}{83}$ 。因此,为进一步提高模型的准确性和泛化能力,未来的研究将重点扩大数据集规模,特别是针对职业驾驶员的分心驾驶行为进行大规模数据采集,这一举措有助于丰富分心驾驶行为数据集的多样性,提升模型对真实场景的适应性,为交通安全领域提供更为可靠的技术支持。

参考文献:

- [1] BEANLAND V, FITZHARRIS M, YOUNG K L, et al. Driver Inattention and Driver Distraction in Serious Casualty Crashes: Data from the Australian National Crash In-Depth Study [J]. *Accident Analysis & Prevention*, 2013, 54: 99-107.
- [2] WICKENS C D. Multiple Resources and Performance Prediction [J]. *Theoretical Issues in Ergonomics Science*, 2002, 3(2): 159-177.
- [3] KABER D B, LIANG Y L, ZHANG Y, et al. Driver Performance Effects of Simultaneous Visual and Cognitive Distraction and Adaptation Behavior [J]. *Transportation Research Part F: Traffic Psychology and Behaviour*, 2012, 15(5): 491-501.
- [4] PENG Y, LOU X, WANG H G, et al. Driving Behavior in Hazardous Situations: The Interplay between Risk Scenarios and Dimensional Emotions [J]. *Transportation Research Part F: Traffic Psychology and Behaviour*, 2024, 107: 695-709.
- [5] BANERJEE A, PATHIVADA B K, HALEEM K, et al. Developing Distraction-Related Safety Performance Functions at Interchange Ramp Terminals in Kentucky [J]. *Journal of Safety Research*, 2025, 93: 66-78.
- [6] BIONDI F N, HORREY W J, DONMEZ B. Preface to the Special Issue on Assessment and Effectiveness of Driver Monitoring Systems [J]. *Human Factors*, 2024, 66(9): 2161-2165.
- [7] KASHEVNIK A, SHCHEDRIN R, KAISER C, et al. Driver Distraction Detection Methods: A Literature Review and Framework [J]. *IEEE Access*, 2021, 9: 60063-60076.
- [8] ZHANG J, WU Z C, LI F, et al. A Deep Learning Framework for Driving Behavior Identification on In-Vehicle CAN-BUS Sensor Data [J]. *Sensors*, 2019, 19(6): 1356.
- [9] 顾清华, 殷书檀, 王丹, 等. 基于改进 YOLOv8 的矿卡司机疲劳驾驶检测 [J]. *中国安全科学学报*, 2025, 35(1): 60-66.
- [10] KHAN M A, NAWAZ T, KHAN U S, et al. IoT-Based Non-Intrusive Automated Driver Drowsiness Monitoring Framework for Logistics and Public Transport Applications to Enhance Road Safety [J]. *IEEE Access*, 2023, 11: 14385-14397.
- [11] FU S C, YANG Z H, MA Y, et al. Advancements in the Intelligent Detection of Driver Fatigue and Distraction: A Comprehensive Review [J]. *Applied Sciences*, 2024, 14(7): 3016.
- [12] XIANG G L, YAO S, WU X H, et al. Driver Multi-Task Emotion Recognition Network Based on Multi-Modal Facial

Video Analysis [J]. Pattern Recognition, 2025, 161: 111241.

[13] REDMON J, DIVVALA S, GIRSHICK R, et al. You Only Look Once: Unified, Real-Time Object Detection [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). New York: IEEE, 2016: 779-788.

[14] GHAHREMANI A, ADAMS S D, NORTON M, et al. Detecting Defects in Solar Panels Using the YOLO V10 and V11 Algorithms [J]. Electronics, 2025, 14(2): 344.

[15] WANG C Y, LIAO H M. YOLOv1 to YOLOv10: The Fastest and Most Accurate Real-Time Object Detection Systems [J]. APSIPA Transactions on Signal and Information Processing, 2024, 13(1): 20240058.

[16] 徐红梅, 杨浩, 李亚林, 等. 基于改进 YOLO-Pose 的复杂环境下拖拉机驾驶员关键点检测 [J]. 农业工程学报, 2023, 39(16): 139-149.

[17] LI R J, YU C D, QIN X R, et al. YOLO-SGC: A Dangerous Driving Behavior Detection Method with Multiscale Spatial-Channel Feature Aggregation [J]. IEEE Sensors Journal, 2024, 24(21): 36044-36056.

[18] LI T, LOU X, YANG Z Q, et al. Clarifying the Impact of Engine Operating Parameters of Heavy-Duty Diesel Vehicles on NOx and CO2 Emissions Using Multimodal Fusion Methods [J]. Science of The Total Environment, 2024, 954: 176598.

[19] NORDFJAERN T, JØRGENSEN S H, RUNDMO T. Safety Attitudes, Behaviour, Anxiety and Perceived Control among Professional and Non-Professional Drivers [J]. Journal of Risk Research, 2012, 15(8): 875-896.

[20] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional Block Attention Module [M] // FERRARI V, HEBERT M, SMINCHISESCU C, et al. Computer Vision . Cham: Springer International Publishing, 2018: 3-19.

[21] CHEN J R, KAO S H, HE H, et al. Run, Don't Walk: Chasing Higher FLOPS for Faster Neural Networks [EB/OL]. (2023-03-15) [2024-04-30]. <https://arxiv.org/abs/2303.03667v3>.

[22] WANG J, LI W J, LI F, et al. 100-Driver: A Large-Scale, Diverse Dataset for Distracted Driver Classification [J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(7): 7061-7072.

[23] ALJOHANI A A. Real-Time Driver Distraction Recognition: A Hybrid Genetic Deep Network Based Approach [J]. Alexandria Engineering Journal, 2023, 66: 377-389.

[24] TURNBULL P R K, KHANAL S, DAKIN S C. The Effect of Cellphone Position on Driving and Gaze Behaviour [J]. Scientific Reports, 2021, 11(1): 7692.

[25] WANG C, LIN M H, SHAO L, et al. MF-YOLO: A Lightweight Method for Real-Time Dangerous Driving Behavior Detection [J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 5035213.

责任编辑 张 桐
柳 剑