

# 基于YOLOv8的驾驶员分心状态识别算法研究

庞夏君, 刘玉情

广西职业技术学院人工智能学院, 广西 南宁

收稿日期: 2025年12月24日; 录用日期: 2026年1月28日; 发布日期: 2026年2月9日

## 摘要

准确、快速检测分心驾驶行为对于提高道路安全和预防交通事故至关重要。从驾驶员分心驾驶行为特点出发, 提出了基于改进YOLOv8n的分心驾驶行为检测算法。首先是引入了简单注意力机制(SimAM)对每个特征图进行自归一化, 强调具有有价值信息的特征图, 抑制复杂背景中的冗余信息干扰。其次为了提高对小目标物体的检测性能, 增加了小目标检测层, 使模型能够更准确地检测和定位尺寸较小的目标, 提高目标检测系统在复杂场景下的稳定性和鲁棒性。最后在公开和收集到的数据集上进行了验证, 模型精度提高了4.2%。分心驾驶检测准确率分别达到90.4%验证了所提模型在辅助驾驶时分心驾驶检测和降低事故风险方面的卓越性能。

## 关键词

分心驾驶, YOLOv8n, 注意力机制, 小目标检测

# Research on Driver Distracted State Recognition Algorithm Based on YOLOv8

Xiajun Pang, Yuqing Liu

School of Artificial Intelligence, Guangxi Vocational and Technical College, Nanning Guangxi

Received: December 24, 2025; accepted: January 28, 2026; published: February 9, 2026

## Abstract

Accurate and rapid detection of distracted driving behavior is critical to improving road safety and preventing traffic accidents. Based on the characteristics of drivers' distracted driving behavior, an improved YOLOv8n distracted driving behavior detection algorithm is proposed. Firstly, a simple attention mechanism (SimAM) is introduced to self-normalize each feature map, emphasizing the feature maps with valuable information and suppressing the interference of redundant information in complex background. Secondly, in order to improve the detection performance of small target objects, a small target detection layer is added, so that the model can detect and locate smaller targets more accurately, and improve the stability and robustness of the target detection system in

complex scenes. Finally, the accuracy of the model is improved by 4.2% on the published and collected data sets. The accuracy of distracted driving detection reached 90.4% respectively, which verified the excellent performance of the proposed model in detecting distracted driving and reducing accident risk during assisted driving.

## Keywords

Distracted Driving, YOLOv8n, Attention Mechanism, Small Target Detection

Copyright © 2026 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

根据 2023 年公安部交通管理局最新的数据，我国截至当年底的机动车保有量已达 4.35 亿辆，与上年相比增长了 0.05% [1]。然而，随着机动车数量的不断增加，我们面临着交通拥堵和交通事故频发等问题。英国的统计数据显示，有 70% 的致命交通事故是由驾驶人注意力不集中引起的。研究表明，驾驶人在开车时接打电话会使交通事故发生概率增加 2.8 倍，而发信息时这一概率则增加了 23 倍 [2]。分心驾驶还可能导致事故的严重程度加剧，因此对驾驶员分心状态进行识别和检测的研究具有重要意义。

目前有基于生理信号的驾驶行为监测技术，如 Chu 等 [3] 通过监测分析驾驶员分心驾驶时的脑电信号 (EEG) 的变化，发现  $\alpha$ 、 $\beta$ 、 $\gamma$  等脑电波与驾驶员分心状态有着显著联系；有基于深度学习的驾驶行为监测技术，如 Tran 等人 [4] 分析比较了 AlexNet、GoogleNet、VGG-16 和 ResNet 四种深度卷积神经网络 [5] [6] 在分心驾驶任务中的表现，实验结果表明 GoogleNet 的检测效果最好。但上述检测算法中都存在检测速度慢，准确率低等问题，本文采用改进的 YOLOv8 算法，以权衡驾驶分心行为识别的可行性和精度为目标，实现快速、准确的驾驶员分心驾驶行为识别 [7]-[9]。

## 2. 方法

### 2.1. YOLOv8n 网络结构

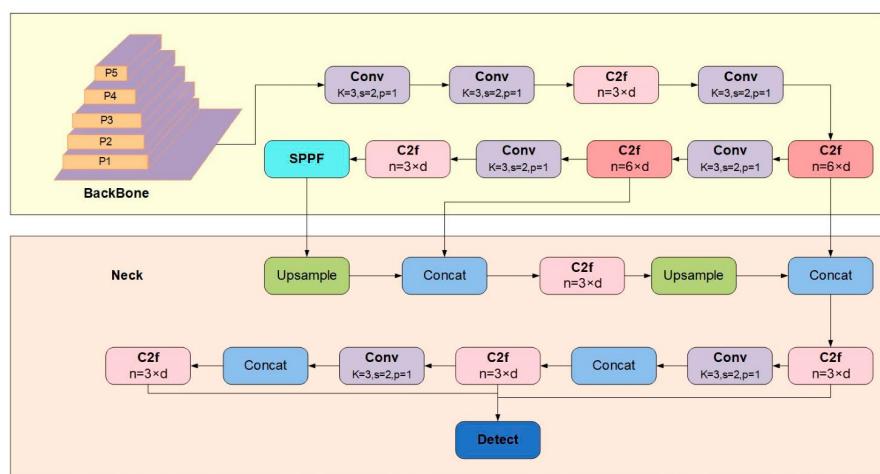


Figure 1. Structure diagram of YOLOv8n [11]

图 1. YOLOv8n 的结构图 [11]

YOLOv8 是一种基于回归技术的单阶段目标检测算法, 旨在进一步提高检测性能。该模型包含四种不同的网络结构: YOLOv8n、YOLOv8s、YOLOv8m、YOLOv8l 和 YOLOv8x [10]。这些架构在深度和广度方面都得到了支持, 以提高检测精度, 尽管代价是增加了计算复杂性。鉴于分心驾驶检测所需的高速响应能力, 我们选择了以速度快著称的 YOLOv8n 模型作为基准, 并随后对其进行了优化。YOLOv8s 模型由四个关键组件组成: 输入层、骨干网络层、颈部结构和输出层, 如图 1 所示。

## 2.2. 改进的 YOLO8n 网络结构

### 2.2.1. SimAM 注意力机制

在实际驾驶场景中, 驾驶员背景的多样性使得准确识别分心驾驶行为成为相当大的挑战。在这种情况下, 为了更有效地提取关键信息, 注意力机制已被广泛用于分心驾驶行为的研究。然而, 现有的注意力模块存在两个问题: 首先, 它们只能在通道或空间维度上细化特征, 这种限制使得它们难以灵活地学习不同通道和空间位置中的注意力权重。下图呈现了两种常见的注意力模块: (1) 通道注意力模块该模块对相同通道的不同位置的特征同等对待, 从而区别对待不同通道的特征。(2) 空间注意力模块该模块对某一位置的不同通道同等对待, 而对同一通道上的不同位置区别对待。然而, 人类的注意力应当是空间、通道两种注意力协同工作, 即每个神经元都应当区别对待。

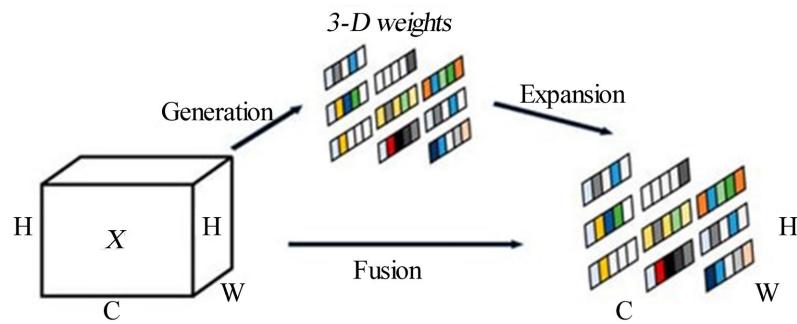
此外, 目前注意力机制的结构通常是由一系列复杂的单元组合而成, 常见的注意力机制往往采用额外的子网络生成注意力权值, 如 SENet (Squeeze and Excitation Networks), 其结构由全局平均池化、全连接层、Sigmoid 模块、ReLU 激活函数[12]-[14]等单元组成, 这些网络结构复杂, 其中包含大量全连接、池化等操作, 众多单元的计算需要大量算力。表 1 展示了目前几个主流的注意力模块额外引入的参数量, 从中可以看出, SimAM 注意力机制是一种无参注意力机制, 相比其他注意力机制, SimAM 在增加模型特征提取能力的同时, 不会带来模型参数量的增加。

**Table 1.** Comparison of different attention mechanisms

**表 1.** 不同注意力机制对比表

注意力机制	参数量
SE	$2C^2/r$
CBAM	$2C^2/r + 2k^2$
GC	$2C^2/r + C$
ECA	$k$
SRM	$6C$
SimAM	0

因此, 这项研究引入了 SimAM 注意力机制[15]-[17], 如图 2 所示。SimAM 是一种三维注意力模块, 通过使用能量函数计算注意力权重, 是一个简单但非常有效的卷积神经网络的注意力模块。通过设计能量函数来计算注意力权重, 能够灵活、有效地提升神经网络的表征能力。SimAM 注意力模块将空间注意力与通道注意力以并行或串联的方式相结合, 在不引入额外参数的情况下, 从特征图中提取 3D 注意力权重, 提出了优化能量函数以探索每个神经元的重要性。利用统一权重的注意力模块改善了能量函数以揭示神经元的重要性, 推导出了能量函数的解析解, 加速了注意力权重的计算, 并设计了一种轻量级注意力模块。

**Figure 2.** SimAM attention structure [18]**图 2.** SimAM 注意力结构[18]

SimAM 算法首先对每个神经元的重要性进行评估。在神经科学领域中，信息丰富的神经元通常展现出与周围神经元不同的放电模式。此外，激活的神经元往往抑制周围的神经元，即存在空域抑制效应。因此，具有空域抑制效应的神经元应被视为具有更高的重要性。SimAM 算法通过衡量神经元之间的线性可分性来识别重要神经元，从而定义以下能量函数：

$$e_t(w_t, b_t, y, x_i) = (y_t - \hat{t})^2 + \frac{1}{M-1} \sum_{i=1}^{M-1} (y_0 - \hat{x}_i)^2 \quad (1)$$

$$\hat{t} = w_t \times t + b_t \quad (2)$$

$$\hat{x}_i = w_t \times x_i + b_t \quad (3)$$

其中， $t$  表示输入特征矩阵中某一通道的目标神经元， $x_i$  是该通道中的其他神经元， $M$  则是该通道中神经元的总数量， $i$  为空间维度索引， $\hat{t}$  是关于  $t$  的线性变换， $\hat{x}_i$  是关于  $x_i$  的线性变换， $w_t$  是线性变换的权重， $b_t$  则是线性变换的偏置项。公式(1)中的变量都是标量， $y_t$  不等于  $y_0$ ，因此当  $y_t = \hat{t}$  且  $y_0 = \hat{x}_i$  时，公式(1)达到最小值，而最小化公式(1)代表着找到了同一个通道中目标神经元  $t$  和其他神经元的线性可分性。对  $y_t$  和  $y_0$  进行二进制表达(-1 和 1)，并在公式(1)中引入正则项，最终的能量函数的表达式如下。

$$e_t = \frac{1}{M-1} \sum_{i=1}^{M-1} (-1 - \hat{x}_i)^2 + (1 - \hat{t})^2 + \lambda w_t^2 \quad (4)$$

理论上，每个通道上的能量函数都有  $M$  个。如果使用 SGD 等迭代算法来求解，那么计算将是繁重的。幸运的是，公式(4)有  $w_t$  和  $b_t$  的解析解，如公式(5)和公式(6)所示。

$$w_t = -\frac{2(t - \mu_t)}{(t - \mu_t)^2 + 2 \times \sigma_t^2 + 2 \times \lambda} \quad (5)$$

$$b_t = -\frac{1}{2}(t + \mu_t) \times w_t \quad (6)$$

其中， $\mu_t$  是目标通道中除神经元  $t$  之外其他神经元的平均值， $\sigma_t^2$  是目标通道中除神经元  $t$  之外其他神经元的方差，其计算公式如下：

$$\mu_t = \frac{1}{M-1} \sum_{i=1}^{M-1} x_i \quad (7)$$

$$\sigma_t^2 = \frac{1}{M-1} \sum_{i=1}^{M-1} (x_i - \mu_t)^2 \quad (8)$$

由于公式(7)和公式(8)代表的是在单个通道上获得的解析解，因此 Yang 等人对此做了一个合理的假

设, 即假设在单个通道中, 每个像素都服从相同的分布。基于这个假设, 可以计算出该通道上所有神经元输出值的平均值和方差。通过这种方式可以赋予该通道上的所有神经元更高的重要性, 因为它们共享相似的数据特征, 这有助于模型更好地理解和利用通道内的信息。同时, 它可以防止预测模型迭代计算每一个位置上的  $\mu$  和  $\sigma$ , 显著地降低了模型的计算量。综上, 最小能量的计算表, 达式如下所示:

$$e_t^* = \frac{4 \times (\hat{\sigma}^2 + \lambda)}{(t - \hat{\mu})^2 + 2 \times \hat{\sigma}^2 + 2 \times \lambda} \quad (9)$$

其中  $\hat{\mu}$  是单个通道中所有神经元的平均值,  $\hat{\sigma}^2$  是单个通道所有神经元的方差, 计算公式如下:

$$\hat{\mu} = \frac{1}{M} \sum_{i=1}^M x_i \quad (10)$$

$$\hat{\sigma}^2 = \frac{1}{M} \sum_{i=1}^M (x_i - \hat{\mu})^2 \quad (11)$$

公式(9)表明, 当神经元  $t$  的能量越低时, 神经元  $t$  与它附近的神经元之间存在的差异越大, 在视觉处理中预测模型对神经元  $t$  的关注就越多。因此, 各个神经元的权重可以通过计算  $1/e_t^*$  得到。最后, 经过 SimAM 注意力机制增强后的特征  $\tilde{X}$  的最终结果如式(12)所示。

$$\tilde{X} = \text{sigmoid}\left(\frac{1}{E}\right) \odot X \quad (12)$$

$X$  为输入的特征图,  $\tilde{X}$  为增强后的特征图。 $E$  为特征图中所有  $e_t^*$  值的集合。 $\odot$  为点积运算。为防止  $E$  值出现过大的情况, 通过 sigmoid 函数来限制  $E$  值。

具体来说, SimAM 计算能量, 并推断当特定神经元的能量较低时, 其与其他神经元的差异越大, 表明其重要性较高。因此, SimAM 注意机制在不引入额外参数的情况下, 能够准确捕获图像特征中的关键信息, 具有较大的实际应用价值。改进后的网络结构如图 3 所示。

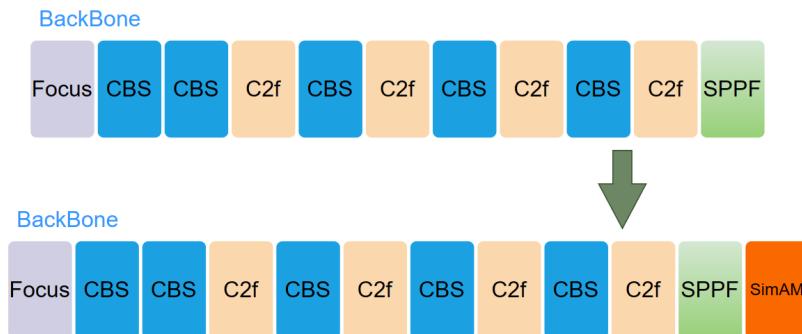


Figure 3. Comparison of the structure of the Backbone network before and after improvement

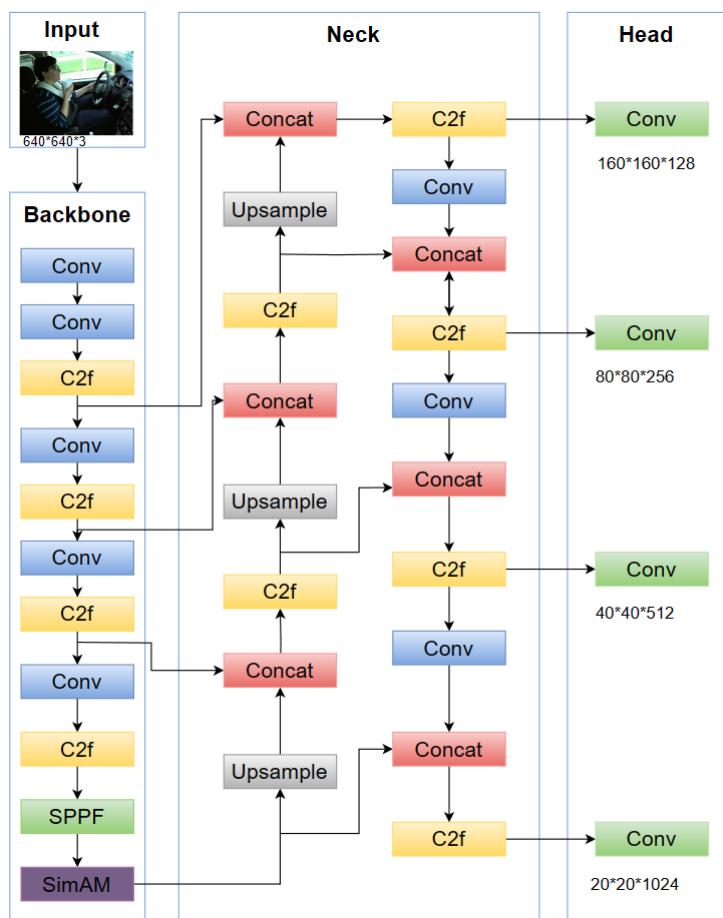
图 3. 改进前后 Backbone 端的结构对比

在 YOLOv8 的 Backbone 结构中引入 SimAM 注意力模块, 使模型充分利用有限的 GPU 资源, 筛选出更为有价值的目标特征信息, 通过引入 SimAM 注意力模块, 实现在不增加模型参数、网络模型深度的前提下, 增加特征的提取效率, 提高模型的检测性能。在目标检测任务中, 主干网络对不同目标关注的特征是多样的。初始阶段以相同的重视程度处理每个特征图可以加快网络的收敛速度。同时, 在保持实时性的同时, SimAM 无参注意力模块不引入额外参数, 有助于保持模型的紧凑性, 并且在不损害性能的情况下提高了平均精度(mAP), 因此选择 SimAM 无参注意力模块是一个明智的选择。

### 2.2.2. 小目标检测层

小目标检测一直是目标检测领域的一个挑战，因为小目标通常具有较低的分辨率和较少的特征信息，容易被忽略或误分类。在原始的 YOLOv8 中，由于采用了相对于原图较大的下采样倍率，即较大的感受野，虽然可以预测一些尺度较大的目标，但较小的目标往往无法得到充分地注意和精确地定位，因此，YOLOv8 原始模型在检测小目标方面表现不佳。该模型的输入图像大小为  $640 \times 640$ ，最小检测尺度为  $80 \times 80$ ，每个网格的感受野为  $8 \times 8$ 。如果原始图像中的目标尺寸小于 8 像素，原始网络将很难识别网格内的目标特征信息<sup>[19]</sup>。

因此，本研究提出了增加小目标检测层的方法，在模型中增加了一个  $160 \times 160$  尺度的小目标检测层，如图 4 中的黑色框所示。该层包括额外的融合特征层和新增的检测头，旨在增强小目标的语义信息和特征表达能力。首先，将主干网络(Backbone)中的第五层的  $80 \times 80$  尺度特征层与特征金字塔网络(Neck)中的上采样特征层继续向上堆叠，经过通道到空间的处理和上采样操作后，得到一个深层语义特征层，其中包含小目标的特征信息。接着，将这一深层特征层与主干网络中第三层的浅层位置特征层进行堆叠，以完善  $160 \times 160$  尺度的融合特征层，以增强对小目标的语义特征和位置信息表达能力。最后，通过一个额外的解耦头(Dcoupled Head)将这些特征送入模型的输出层[20]。



**Figure 4.** Small object detection layer network  
图 4. 小目标检测层网络

因此，通过在 Head 部分进行补充，小目标的特征信息得以通过结构传递至其他三个尺度的特征层，

从而增强网络的特征融合能力, 提高小目标的检测准确性。同时, 引入额外的解耦头可扩大对驾驶员分心行为的检测范围, 另外, 通过增加专门的小目标检测头, 可以提供更多的定位信息, 从而减少目标定位的误差。检测精度以及范围的改进, 使得网络更加精确地识别驾驶员的分心行为。

### 2.2.3. 改进 Loss 损失函数

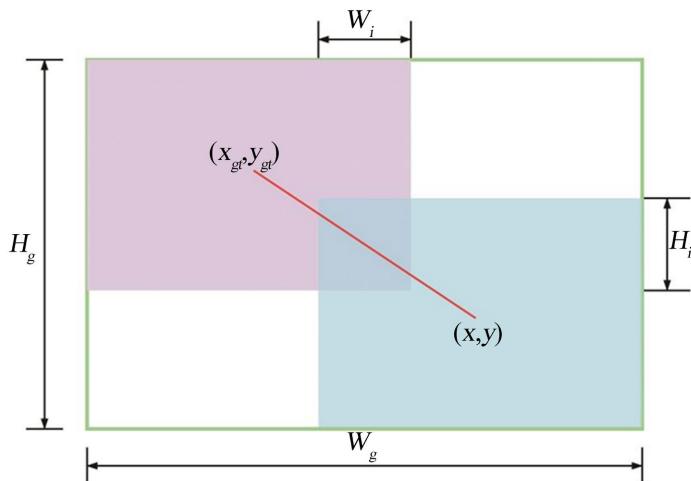
边界框回归的损失函数在目标检测中扮演着关键角色, 其良好定义将显著提升模型性能。在 YOLOv8 中, 采用了 CIoU 作为边界框回归损失函数, 它综合考虑了预测框与真实框的长宽比、中心点距离和重叠面积, 从而提高了回归定位的准确性, 如图 5 所示。然而, 对于小标注框和低质量标注框的回归, CIoU 仍存在一定局限性。为解决这一问题, 提出了(Focal Efficient Intersection over Union, Focal EIOU) v1, 但由于其静态聚焦机制(FM), 未充分发挥非单调 FM 的潜力。因此, 本研究引入了具有动态非单调聚焦机制的 WIoU 损失函数来优化模型。通过动态非单调聚焦机制, 将 IoU 替换为离群度来评估锚框质量, 以减弱几何因素对模型的过度惩罚, 降低对模型训练的干预, 从而增强模型的泛化能力, 即:

$$\mathcal{L}_{\text{IoU}} = 1 - \text{IoU} = 1 - \frac{W_i H_i}{S_u} \quad (13)$$

$$\mathcal{L}_{\text{WIoU}} = \mathcal{R}_{\text{WIoU}} \mathcal{L}_{\text{IoU}} \quad (14)$$

$$\mathcal{R}_{\text{WIoU}} = \exp \left( \frac{\left( x - x_{gt} \right)^2 + \left( y - y_{gt} \right)^2}{\left( W_g^2 + H_g^2 \right)^*} \right) \quad (15)$$

式中,  $W_g$  和  $H_g$  代表预测框和真实框的最小外接框的宽度和高度, 而  $W_i$  和  $H_i$  则是预测框和真实框相交区域的宽度和高度,  $S_u$  表示预测框和真实框的联合区域。为了避免 WIoU 产生阻碍收敛的梯度,  $W_g$  和  $H_g$  被分离出来(上标\*表示此操作)。这种分离操作有效地消除了阻碍收敛的因素, 无需引入新的度量, 如纵横比。因此, 这降低了 CIoU 损失函数中长宽比对函数收敛的影响。



**Figure 5.** Schematic diagram of predicted bounding boxes and ground truth bounding boxes  
**图 5.** 预测框与真实框示意图

Wise-IoU 不仅考虑了目标之间的相对位置和大小差异, 还引入了一种智能权重调整机制, 可以自适地调整权重系数, 提高驾驶员分心检测的灵活性和鲁棒性。本文使用 WIoU 损失函数替换原始 YOLOv8 中的边界框回归损失函数对模型进行优化。

### 3. 实验和结果

#### 3.1. 数据集

为了更好地表现机动车行驶场景下驾驶员的疲劳状态和检验模型的性能,本文通过公开数据集 State Farm Distracted Driver Detection 数据集和自行从网上收集的真实驾驶环境中的司机图像进行训练,其中包含了驾驶员抽烟、玩手机和喝饮料三类。这三类行为在真实驾驶中不仅出现频率高、危险系数大,是引发交通事故的主要分心因素,而且其识别过程往往涉及对手部小目标物体(如手机、香烟、饮料瓶)的检测,能够有效验证本文所引入的小目标检测层与注意力机制在复杂背景下的特征提取与定位能力。因此,研究聚焦于上述三类行为进行实验。筛选后,对这三类行为的图像进行统一标注,并与自行收集的真实驾驶场景图像进行合并,构建最终用于训练与测试的数据集。如图 6 所示,即为数据集的部分样本图像。



**Figure 6.** Sample images

**图 6.** 部分样本图像

#### 3.2. 实验环境和评估指标

本实验使用所搭建的分心驾驶行为检测系统完成测试实验,在训练卷积神经网络的模型时,使用的是具有 GPU 计算加速功能的服务器,服务器配置环境如表 2 所示。该实验采取了以下一组超参数: 初始学习率为 0.01, 权重衰减系数为 0.0005, 迭代次数为 300, 批次大小为 16。

**Table 2.** Server configuration environment

**表 2.** 服务器配置环境

名称	配置
系统	ubuntu20.04
CPU 版本	Intel (R) Xeon (R) Gold 6330
GPU 版本	RTX 3090
内存	80GB
显存	24GB x 1
深度学习框架	PyTorch 1.10.0

为了确保更精确地评估目标检测性能, 引入了四个基本指标: 精确率( $P$ )、召回率( $R$ )、FPS 和平均精度均值(mAP)。这些指标的具体计算公式如下(等式(16)~(18)):

$$P = \frac{TP}{TP + FP} \quad (16)$$

$$R = \frac{TP}{TP + FN} \quad (17)$$

$$AP = \frac{1}{0} \int P(R) dR \quad (18)$$

### 3.3. 实验结果分析

#### 3.3.1. 消融实验

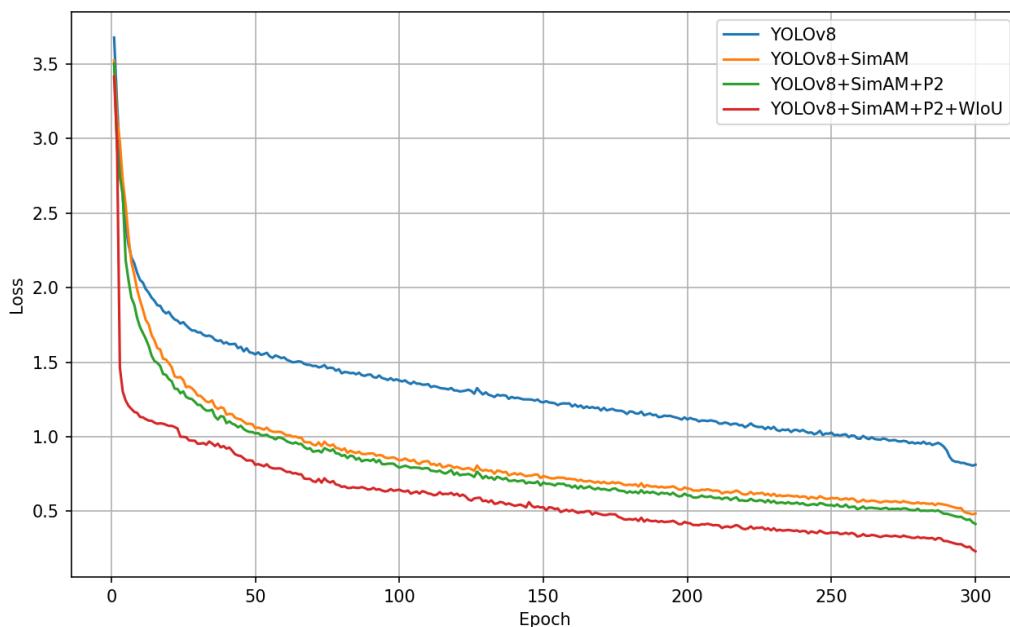
归纳总结本章的实验结果, 应用在 YOLOv8 上的各项改进措施与之对应的准确率如图表 3 所示。

**Table 3.** Ablation study

**表 3. 消融实验**

模型	注意力机制	小目标检测层	损失函数	精确率(%)	召回率(%)
YOLOv8				86.2	86.4
改进模型一	√			87.8	88.1
改进模型二	√	√		88.3	88.1
改进模型三	√	√	√	90.4	90.12

从表中可以得出以下结论: 与原 YOLOv8 相比, 增加注意力机制后、加入了 P2 小目标检测层和改进损失函数后, 模型的精确率和召回率都有所提高。说明改进后的 YOLOv8 驾驶员分析状态识别模型具有可靠性和实用性, 具有明显的优势。



**Figure 7.** Comparison of network loss functions

**图 7. 网络损失函数对比图**

网络的损失函数对比图如图 7 所示。

由上图可以看出, 训练过程中四个网路的损失值都逐渐减小。并且都是在前 200 个 epoch 时损失函数下降较快, 在第 250 个 epoch 时模型慢慢收敛, 改进后的 YOLOv8 网络即 YOLOv8 + SimAM + P2 + WIoU 网络的收敛效果最好, 损失值为 0.232。

### 3.3.2. 对比实验

为了体现本文改进的模型具有良好的性能, 使用相同的数据训练 Faster-RCNN、SSD、YOLOv7、YOLOv8 等模型进行对比, 本文所改进的模型在 mAP 和检测速度上均有一定的优势。各模型的检测结果如表 4 所示。

**Table 4.** comparison of experimental results

**表 4. 对比实验结果**

模型	mAP	face	smoke	phone	drink	检测速度(FPS)
Faster-RCNN	75.44	91.38	51.41	65.44	93.51	36
SSD	72.73	93.54	37.90	69.70	89.76	47
YOLOv7	85.71	93.13	77.37	82.10	91.24	67
YOLOv8	87.18	92.60	79.90	84.20	92.00	75
本文算法	90.50	94.50	82.80	88.80	95.80	73

由表中数据可看出, 本文算法的 mAP 相较于原 YOLOv8 提升了 3.32 个百分点, 主要体现在香烟和手机等小物体的检测上。对比两种算法的每秒帧率, 改进后的 YOLOv8 相较于原 YOLOv8 下降了 2FPS。这是由于改进后的 YOLOv8 模型添加了小目标检测层, 增加了网络的深度和宽度, 从而导致模型参数数量的增加, 但提升了小目标的检测效果。

## 4. 结论

为了及时发现驾驶员的分心驾驶行为以减少交通事故的发生, 本文提出了改进的 YOLOv8 模型。为了筛选出更为有价值的目标特征信息, 添加了 SimAM 注意力机制; 针对 YOLOv8 原模型对小目标的检测能力较差, 对较小的目标往往无法得到充分的注意和精确地定位, 所以增加小目标检测层; 并通过损失函数的改进, 提高模型的性能。该模型在分心驾驶行为检测方面优于较新的 YOLOv8 模型, 获得了更准确的检测结果[21] [22]。

未来, 为了确保我们的模型能够有效地部署在计算资源有限的车辆设备上, 我们的目标是探索模型压缩技术, 如量化和修剪, 以进一步减小模型参数和权重文件的大小。考虑到车辆应用对延迟敏感的性质, 我们也在考虑使用边缘计算解决方案。这将使数据处理更接近数据源, 确保更快的响应时间。此外, 为了提高模型的检测性能, 我们正在考虑将注意力机制的概念与轻量级网络架构相结合, 在不增加计算成本的情况下提高检测性能。

## 参考文献

- [1] 金朝力, 冉黎黎. 2023 年全国机动车保有量达 4.35 亿辆[N]. 北京商报, 2024-01-12(003).
- [2] 巩建国, 赵琳娜. 分心驾驶行为演变与防治对策研究[J]. 汽车与安全, 2015(11): 69-72.
- [3] Chu, Y., Chowdhury, H.R., Mitul, A.F., Uddin, N., Hossain, M.J. and Aslam, D.M. (2019) Nature of Distracted Driving in Various Physiological Conditions. *Applications of Machine Learning*, **11139**, 11139B.  
<https://doi.org/10.11117/12.2535411>

- 
- [4] Tran, D., Manh Do, H., Sheng, W., Bai, H. and Chowdhary, G. (2018) Real-Time Detection of Distracted Driving Based on Deep Learning. *IET Intelligent Transport Systems*, **12**, 1210-1219. <https://doi.org/10.1049/iet-its.2018.5172>
  - [5] 梁昭德. 基于卷积神经网络的驾驶人疲劳检测算法研究[D]: [硕士学位论文]. 广州: 华南理工大学, 2018.
  - [6] 陈军, 张黎, 周博, 等. 基于级联卷积神经网络的驾驶员分心驾驶行为检测[J]. 科学技术与工程, 2020, 20(14): 5702-5708.
  - [7] 李涛. 基于深度学习的复杂场景下车载图像目标检测方法研究[D]: [硕士学位论文]. 重庆: 重庆大学, 2018.
  - [8] 孙玥, 杨国为, 陈雪鑫. 基于计算机视觉的疲劳及注意力检测算法[J]. 计算机与数字工程, 2021, 49(6): 1195-1198.
  - [9] Du, Y., Liu, X., Yi, Y. and Wei, K. (2023) Optimizing Road Safety: Advancements in Lightweight YOLOv8 Models and GhostC2f Design for Real-Time Distracted Driving Detection. *Sensors*, **23**, Article 8844. <https://doi.org/10.3390/s23218844>
  - [10] 周飞, 郭杜杜, 王洋, 等. 基于改进 YOLOv8 的交通监控车辆检测算法[J]. 计算机工程与应用, 2024, 60(6): 110-120.
  - [11] Ultralytics (2026) YOLOv8 Documentation. <https://docs.ultralytics.com/models/yolov8/>
  - [12] 蒋昂波, 王维维. ReLU 激活函数优化研究[J]. 传感器与微系统, 2018, 37(2): 50-52.
  - [13] 宋鹏飞, 吴云. DenseNet 和 SeNet 融合残差结构的 DR 分类方法[J]. 计算机应用研究, 2024, 41(3): 928-932+950.
  - [14] 刘丽伟, 侯德彪, 侯阿临, 等. 基于 SimAM-YOLOv4 的自动驾驶目标检测算法[J]. 长春工业大学学报, 2022, 43(3): 244-250.
  - [15] Perez, J., Hyun, K. and Boni, J.A. (2024) Use of Smartphone Apps While Driving: Variations on Driving Performances and Perceived Risks. *Accident Analysis & Prevention*, **198**, Article 107474. <https://doi.org/10.1016/j.aap.2024.107474>
  - [16] Abbass, M.A.B. and Ban, Y. (2024) Mobilenet-Based Architecture for Distracted Human Driver Detection of Autonomous Cars. *Electronics*, **13**, Article 365. <https://doi.org/10.3390/electronics13020365>
  - [17] Demir, B., Demir, S., Wickens, C.M., et al. (2024) Exploring the Behaviour Change Wheel and the Theoretical Domains Framework in Interventions for Mobile Phone Driver Distraction: A Scoping Review. *Accident Analysis and Prevention*, **195**, Article 107369.
  - [18] Chen, Z.J., Xie, L., Zhang, J. and Lin, L. (2021) SimAM: A Simple, Parameter-Free Attention Module for Convolutional Neural Networks. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Nashville, 19-25 June 2021, 11899-11908.
  - [19] Leekha, M., Goswami, M., Shah, R.R., Yin, Y. and Zimmermann, R. (2019) Are You Paying Attention? Detecting Distracted Driving in Real-Time. 2019 *IEEE Fifth International Conference on Multimedia Big Data (BigMM)*, Singapore, 11-13 September 2019, 171-180. <https://doi.org/10.1109/bigmm.2019.00-28>
  - [20] Alzubaidi, L., Zhang, J., Humaidi, A.J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., et al. (2021) Review of Deep Learning: Concepts, CNN Architectures, Challenges, Applications, Future Directions. *Journal of Big Data*, **8**, Article No. 53. <https://doi.org/10.1186/s40537-021-00444-8>
  - [21] Eraqi, H.M., Abouelnaga, Y., Saad, M.H. and Moustafa, M.N. (2019) Driver Distraction Identification with an Ensemble of Convolutional Neural Networks. *Journal of Advanced Transportation*, **2019**, 1-12. <https://doi.org/10.1155/2019/4125865>
  - [22] Liu, S., Qi, L., Qin, H., Shi, J. and Jia, J. (2018) Path Aggregation Network for Instance Segmentation. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 18-23 June 2018, 8759-8768. <https://doi.org/10.1109/cvpr.2018.00913>