

# 基于机器视觉的雨雾天驾驶辅助系统设计

洪儒, 于力涵, 戴安邦, 谢迎娟  
(河海大学 信息科学与工程学院, 江苏 常州 213002)

**摘要:** 随着私家车数量日益增多, 雨雾天交通安全问题成为了亟待解决的难题; 在嵌入式硬件资源有限的情况下, 为驾驶用户设计了基于机器视觉的雨雾天语音辅助驾驶系统; 系统结合了湿度传感器、轻量化去雾神经网络 AOD-NET 和目标检测模型 YOLOv5n; 在目标检测模型 YOLOv5n 上, 利用 K-means++ 算法重新设计锚框, 选取较优的骨干网络并利用模型剪枝进一步压缩模型大小; 实验结果表明, 改进的模型在 Jetson nano 上的 FPS 达到了 17.78, 最终 mAP 在人工加雾、分辨率变化的 TT100K (Tsinghua-Tencent 100K) 数据集上达到了 65.8%, 满足了正常天气与雨雾天气下的驾驶辅助实际应用。

**关键词:** 机器视觉; Jetson nano; 雨雾天辅助驾驶; 交通标志检测; AOD-NET 去雾; YOLOv5n

## Design of Driving Assistance System under Rain and Haze Weather Based on Machine Vision

HONG Ru, YU Lihan, DAI Anbang, Xie Yingjuan

(School of Information Science and Engineering, Hohai University, Changzhou 213002, China)

**Abstract:** With the increase of private cars, traffic safety in rainy and foggy days has become an urgent problem to be solved. A voice assisted driving system for driving users in rainy and foggy weather based on machine vision is designed, with the limited embedded hardware resources. The system combines the humidity sensors, lightweight dehazing neural network AOD-NET, and object detection model YOLOv5n. The K-means++ algorithm is used to redesign the anchor frame on the object detection model YOLOv5n. The optimal backbone network is selected to further compress the model size by using the model pruning. The experimental results show that the FPS of the improved model on the Jetson nano reaches by 17.78, and the final mAP by 65.8% on the artificially fogged and resolution changed TT100K (Tsinghua-Tencent 100K) dataset, meeting the practical application of driving assistance in normal weather and rainy and foggy weather.

**Keywords:** machine vision; Jetson nano; assisted driving in rain and haze weather; traffic sign detection; AOD-NET dehazing; YOLOv5n

## 0 引言

21 世纪以来, 随着中国私家车数量日益增多, 交通问题成为了阻碍城市发展的关键因素。道路堵塞、交通事故的频繁发生极大地限制了城市的发展。基于交通标志检测的智能辅助驾驶方法则可以实时地为驾驶员提供丰富的路面信息, 从而降低交通事故发生率。因此, 智能辅助驾驶具有较高的研究价值, 成为当下亟待解决的问题<sup>[1-4]</sup>。

而在雨雾天气下, 道路能见度低, 无论是驾驶员还是智能辅助驾驶系统往往都难以准确观察道路车况、捕捉实时信息<sup>[5]</sup>。因此在车辆行驶过程中, 更加容易遇到道路阻塞的情况, 甚至在车辆间发生碰撞、追尾一类的交通事故。基于此, 乔敏<sup>[6]</sup>等人通过维纳复原, 检测了六类道路限速

交通标志, 虽然检测成功率较高, 但算法可识别的种类较少, 难以完成完整的系统构建。张宏宇<sup>[7]</sup>利用改进后的 Faster-RCNN 模型完成了交通标志检测任务, 虽然模型在公开数据集上表现良好, 但由于 Faster-RCNN 模型参数量多, 计算量大, 难以部署在小型设备上并实时检测。除此以外, 现有的雾天场景目标检测大多直接在主流目标检测模型上进行改进, 例如朱开等人<sup>[8]</sup>优化了 YOLOv5 网络, 并将其用于雨雾天气下的交通标志识别, 也有院老虎等学者在 YOLOv5 模型的预测层前加入 CBAM 注意力机制<sup>[9]</sup>。但由于没有采用去雾算法在输入目标检测模型前进行预处理, 因此难以估计直接使用目标检测模型进行训练的效果可否达到先去雾后检测的算法。去雾算法的预处理可以提

收稿日期: 2023-04-29; 修回日期: 2023-06-05。

基金项目: 国家自然科学基金(61573128); 国家自然科学基金(61701169); 国家重点研发计划(2018YFC0407101); 教育部产学研合作协同育人项目(220803494162012, 220603632072407); 国家级大学生创业训练项目(202210294232E); 江苏省大学生创新创业训练计划项目(202210294220Y); 河海大学本科实践教学改革研究项目(河海教务[2022]47号); 河海大学创新性实验项目(河海教务[2022]49号)。

作者简介: 洪儒(2002-), 男, 本科生。

通讯作者: 谢迎娟(1976-), 男, 硕士研究生。

引用格式: 洪儒, 于力涵, 戴安邦, 等. 基于机器视觉的雨雾天驾驶辅助系统设计[J]. 计算机测量与控制, 2024, 32(3): 259-266.

高图像清晰度,能够在很大程度上消除图像中的雾气,使得后续的目标检测模型能够更加准确地识别目标物体;雾气会降低图像的对比度,使得目标物体的边缘模糊不清,去雾算法能够改善图像的对比度,使得目标物体的边缘更加明显,有利于目标检测模型更好地分割目标;在雨雾天气下,图像中的背景往往存在大量的噪声,去雾算法能够降低这些背景噪声,使得目标检测模型更加容易区分目标物体和背景。

上述方法存在的问题可概括如下:识别效果不稳定、模型实时推理慢、有雾图像未过去雾处理、小目标识别能力弱和未部署到资源有限的嵌入式硬件中,难以融入生活实际。

针对以上问题,本文在 Jetson nano 上利用了 AOD-NET 去雾算法与改进后的 YOLOv5 网络,设计了一种基于机器视觉的雨雾天智能语音辅助驾驶系统,对于减少因视线模糊造成的交通隐患和事故有着重要的研究意义与实际应用价值。

本系统的主要创新点包括:

1) 去雾算法与目标检测的结合。本系统利用轻量化去雾神经网络 AOD-NET 预处理有雾图像,应用于后续的交通标志检测,并将其性能与未去雾而直接检测交通标志的模型进行对比。最终,通过比对目标检测模型在去雾前图片与去雾后的图片上的效果,最终实验得出未优化的 YOLOv5n 模型的 mAP 在加雾的 TT100K 数据集上从 56.7% 提高到了 69.1%。在目标检测模型中为了改进小目标检测的效果,本文还改进了 YOLOv5 模型检测时的初始锚框设定,使用了 K-means++ 聚类算法重新设计匹配交通标志检测数据集的先验锚框尺寸<sup>[10]</sup>,以此使得 YOLOv5 模型适应交通标志的小目标检测任务。

2) 模型剪枝的使用。本文对训练完成的 YOLOv5 模型进行了剪枝的操作<sup>[11]</sup>,使得算法在不损失过多精度的情况下,实时性得以提高,更为贴合实际应用的需求。相较于原来的 15.50 FPS,现有的运行处理速率是 24.68 FPS,在加入去雾算法后仍旧可以达到 17.78 FPS。

3) 系统化设计,贴合实际需求。除了算法的设计,本文还基于检测成功的数据,设计了特定的缓冲区以及语音播报方法<sup>[12]</sup>,在检测到交通标志后,无需驾驶员操作,即可通过车载蓝牙音箱或蓝牙耳机播报语音提示,实时提醒驾驶员路面信息,助力安全驾驶。

## 1 系统结构及原理

雨雾天智能语音辅助驾驶系统在完全自动化的方式下,在驾驶途中,为驾驶员提供符合道路状况、天气状况的交通标志语音播报提示信息。其整体方案如图 1。

本系统由摄像头图像采集、外部信息采集、蓝牙语音播报以及搭载改进的交通标志检测算法的 Jetson nano 中央控制器组成。通过 GPIO 采集外部汽车是否启动、湿度,并将其传入中央控制器,中央控制器根据 GPIO 输入的信息,进行下一步操作:当汽车未启动时,不开启图像采集摄像

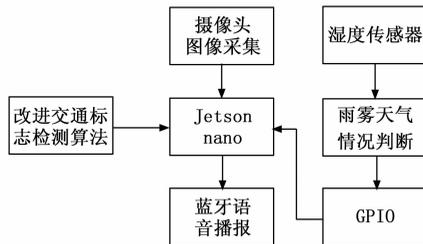


图 1 系统方案示意图

头;当汽车启动而未判断为雨雾天时,采用基本的交通标志检测算法处理采集到的图像;当汽车启动且判断为雨雾天时,中央控制器将采用去雾算法与交通标志检测算法相结合的方式,以更有效地方式处理视线不清晰的雾天图像。最终,中央控制器会将利用采集到的信息控制蓝牙语音播报模块,选择相对应的语音进行播报,辅助驾驶员利用听觉获得更多的路面信息。

## 2 系统硬件组成及其结构

考虑到本系统在实际车载应用中对实时性要求较高,而本文后续提出的图像去雾处理、基于深度学习的目标检测的算法计算量却较大,除此以外,由于车载的特殊应用场合,本系统还要求选择体积较小且便携的硬件平台。

Jetson Nano 是一款低功耗、高性能的嵌入式计算机,由英伟达公司推出。它采用 NVIDIA Maxwell? GPU 架构、四核 ARM Cortex-A57 CPU、4GB LPDDR4 RAM、16GB eMMC 存储、40 针 GPIO (General Purpose Input/Output) 接口、1 个 HDMI 端口、4 个 USB 3.0 端口、千兆以太网接口、802.11ac Wi-Fi、蓝牙 4.1 和 Micro-SD 卡扩展。除此以外,Jetson Nano 还具有完整的软件堆栈,包括 JetPack 软件开发套件、CUDA-X AI 加速库、TensorRT 和 Deep-Stream SDK 等工具,使得开发和部署深度学习和计算机视觉应用变得更加容易和高效<sup>[13]</sup>。

在本系统测试环节中,利用其中的 GPU 进行推理加速;HDMI 端口外接显示屏进行图像显示;USB 端口连接鼠标、键盘和移动硬盘等外设;GPIO 端口读取外接传感器数据;蓝牙连接外部的车载音响或蓝牙耳机。

GPIO 是一种标准接口,可用于控制数字和模拟信号。Jetson Nano 上的 GPIO 接口采用 40 针的扁平电缆连接器,并且支持多种不同的协议和标准,例如 I2C、SPI 和 UART。通过 Jetson Nano 的 GPIO 接口,用户可以轻松地控制各种外设,例如 LED 灯、蜂鸣器、电机、温度传感器等。此外,Jetson Nano 还支持各种软件库和 API,使得 GPIO 编程变得更加简单和易于使用<sup>[14]</sup>。

结合以上因素,本系统最终选取了 Jetson nano 作为硬件主板,既保证了硬件资源满足后续图像处理与深度学习实时计算的需要,也有着灵活性、便携性,其优势可以在车载场合中得到体现。

考虑到本系统以机器视觉为基础,对采集的图像质量要求较高,且由于实际应用场合中实时性的需要,图像采

集设备应尽量消耗更少的资源。基于此,系统选取了与树莓派原装 Raspi-Cam 相同配置的摄像头,既保证了图像采集质量,也减少了资源损耗。

湿度测量单元采用了 DHT11 温湿度模块,将测量的湿度通过 GPIO 传入 Jetson nano, Jetson nano 将通过软件程序判断当前是否为雨雾天,选择是否进行图像去雾预处理,再执行后续交通标志检测程序。

### 3 系统软件总体设计

系统软件总体上由主程序将各个模块串联。主程序在运行后,将通过 GPIO 读取当前 DHT11 传感器获得的大气湿度数据,随后将判断湿度是否超过 90%。若未超过,则判断为非雨雾天气,将通过 OpenCV 调取摄像头,对每一帧图像通过改进的 YOLOv5 模型进行交通标志检测。若湿度超过 90%,则判断为雨雾天气,将通过 OpenCV 调取摄像头,对每一帧图像通过改进的轻量级网络 AOD-NET 进行去雾处理,随后再通过改进的 YOLOv5 模型进行交通标志检测。最终,在识别完成后,若连续 10 帧中出现该标志 8 次以上,并且在此 10 帧的前 20 帧画面中未出现该标志,则将该标志牌信息存入缓冲区中,程序读取缓冲区按顺序通过蓝牙音箱播报提前设定好的各个标志对应的语音文件。例如,当遇到限速标志牌时,将通过语音告知司机“注意前方限速”,提醒司机观察前方限速标志牌及其限速信息,满足了安全驾驶的需要。图 2 为软件运行总体流程图。

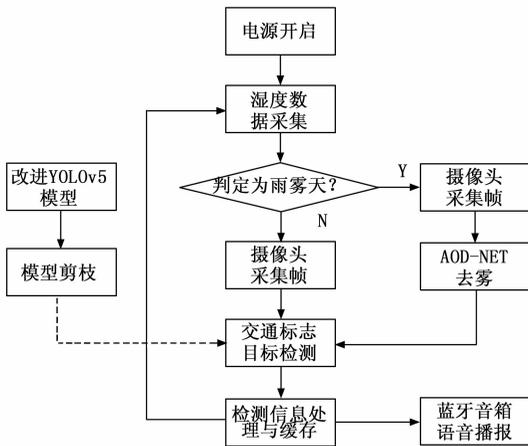


图 2 软件总体流程图

### 4 去雾方法

在雨雾天气中,悬浮在空气中的水微粒对太阳光线有着散射的作用,使得太阳光光强降低,采集到的有雾图像能见度较低,关键的交通标志信息严重缺失,给目标检测网络的特征提取带来了极大的困难,因此使用快速而有效的去雾方法来预处理图像是有必要的。因此在去雾工作中,本文先构建了有雾交通图像数据集,接着选取了合适的去雾方法并与主流方法进行对比,最终将其部署在了嵌入式平台中,以完成工程实际应用。

### 4.1 数据集构建

本文的数据集构建基于简化后的大气散射模型。大气散射模型可以表述为<sup>[15]</sup>:

$$I(i, j) = J(i, j)t(i, j) + A(1 - t(i, j)) \quad (1)$$

其中:  $I(i, j)$  表示有雾图像第  $i$  行、第  $j$  列的像素值,  $J(i, j)$  表示无雾图像第  $i$  行、第  $j$  列的像素值,  $A$  表示大气光强,  $t(i, j)$  表示透射率,与景深有关,可以进一步表示为以下公式:

$$t(i, j) = e^{-\beta(\gamma)d(i, j)} \quad (2)$$

其中:  $\gamma$  表示反射光波长,  $\beta(\gamma)$  表示大气散射系数。

对于交通图像,一般从上至下分别为天空、标志牌、前方汽车和道路。摄像头距离这四类目标距离一般天空最远,标志牌与汽车次之,道路最近,简化图像模型后将距离映射到大气散射模型中的  $d(i, j)$ ,接着映射入  $t(i, j)$  中,即代表从天空、标志牌、前方汽车至道路,能见度将越来越高。这也符合雨雾天气基本的视觉规律为:从图像下方至图像上方,即从行车路面至汽车、标志牌、天空,雾气浓度越来越高,因此可以简化大气散射模型为图 3 (b) 蒙版。依照雨雾天气基本的视觉规律,本文利用 OpenCV 处理来自 TT100K 的交通标志数据集的一批真实路面图像构建了雾气增强图像。图 3 分别为路面原图、雾气蒙版和加雾后的图像。

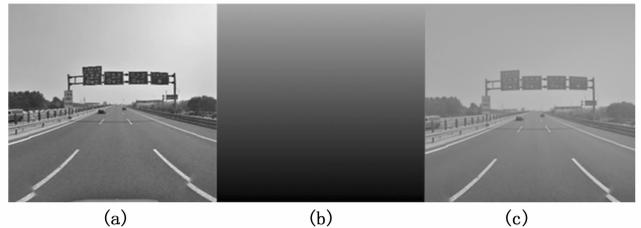


图 3 雾气模拟图

### 4.2 AOD-NET

对于有雾图像,本文采用了基于轻量级深度学习模型 AOD-NET 的去雾方法<sup>[16]</sup>。AOD-NET 网络由参数  $K$  估计与无雾图像生成两个模块组成。具体网络结构可见图 4,其中从 Input 至 Conv5 层均为参数  $K$  估计模块,Output 为无雾图像生成模块。

其中参数  $K$  估计模块基于大气散射模型。AOD-NET 将  $t(i, j)$  与  $A$  合并定义为新的单一变量  $K(i, j)$ :

$$K(i, j) = \frac{1}{t(i, j)} (I(i, j) - A) + A - b \quad (3)$$

在后续的去雾图像生成模块中,  $J(i, j)$  则可以表示为:

$$J(i, j) = K(i, j)I(i, j) - K(i, j) + b \quad (4)$$

AOD-NET 网络每个卷积层只有 3 个卷积核,模型参数很少,因此具有运算量小、速度快、适合实时部署的特点。

### 4.3 实验结果与分析

对比实验在英特尔 i7-12700H CPU@2.30 GHz,内存

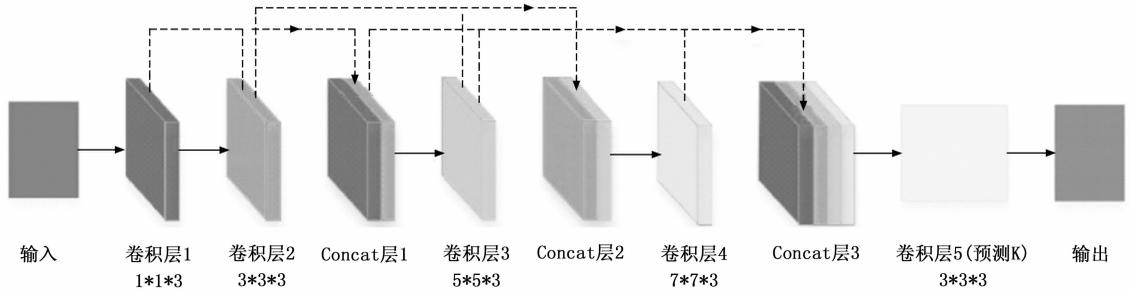


图 4 AOD-NET 网络结构

32 GB, 操作系统 Windows11。选取了直方图均衡化、暗通道先验去雾<sup>[17]</sup>和 AOD-NET 在 100 张交通真实场景图上,在不使用 GPU 的情况下进行对比,通过对比平均 SSIM (结构相似性)、PSNR (平均峰值信噪比)、算法速度和主观评定<sup>[18]</sup>评估了各个算法的可行性。

如表 1 所示,本章选取去雾算法 AOD-NET 的峰值信噪比 PSNR 以及结构相似性 SSIM 均高于直方图均衡化和暗通道先验去雾算法, AOD-NET 生成的去雾图像和无雾清晰图像之间的差距更小,图像具有更高的还原度,说明 AOD-NET 具有较好的去雾效果。除此以外,在算法速度方面, AOD-NET 的速度虽然与传统的直方图均衡化相比较慢,但远远快于暗通道先验去雾算法,符合算法实时性场景的要求,在后续 JetsonNano 嵌入式平台上,神经网络将通过 GPU 进一步加速。

表 1 基于客观指标的主流去雾算法对比

算法名称	平均 SSIM (平均结构相似性)/%	平均 PSNR (平均峰值信噪比)	单张图片 (640 * 480)CPU 处理时间/s
直方图均衡化	83.25	25.40	0.019
暗通道先验去雾法	84.23	27.86	0.080
AOD-NET	89.30	28.30	0.040

图 5 依次为:有雾图像 (a)、直方图均衡化去雾算法 (b)、AOD-NET 去雾算法 (c)、暗通道先验去雾算法 (d) 和无雾原图 (e), 通过对比图 5 中各种主流算法去雾效果。在主观上不难看出直方图均衡化去雾算法天空部分区域呈现红色,失真严重;暗通道先验去雾算法则在天空与其他实物的交界处光线过亮,也有着一定程度的失真;而本文选取的 AOD-NET,与原图、雾图对比来看,去雾效果显著,路标关键信息清晰可见,并且去雾后的图像几乎没有颜色失真,具有最佳的视觉效果和最好的还原效果。经过对比对不同算法速度与效果,本文将选取 AOD-NET 作为输入目标检测模型前图片的预处理去雾算法。

经对比,容易看出直方图均衡化与 AOD-NET 在时间上满足实时部署的基本要求,而 AOD-NET 在本文选取的各个评价指标上表现则要远好于直方图均衡化法,证明在本系统中应用 AOD-NET 来完成去雾是可行的。

### 5 交通标志目标检测方法

交通标志种类繁多,在不同标志间还有许多内部颜色

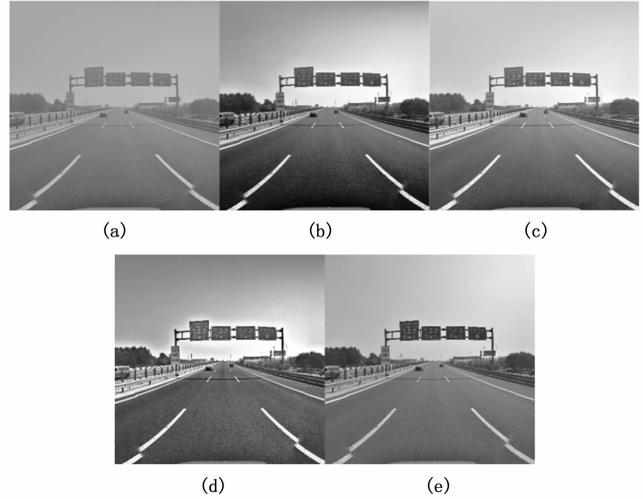


图 5 主流算法去雾效果对比

相同、边框图案相似的情况,因此主流的交通标志目标检测方法中,多采用两阶段算法 R-CNN 与一阶段算法 YOLO,这两类算法的优点是识别准确率高、特征提取能力强、有公开预训练权重因而容易收敛,在理论上均适合应用于交通标志检测<sup>[19]</sup>。但由于两阶段算法 R-CNN 模型参数量较多,且计算分为两阶段耗时较长,所以不适合部署在嵌入式平台上进行实时推理。因此本文选择在 YOLOv5 模型上进行进一步改进,既可以保证模型的检测效果,又在后续处理中节省了计算资源,使得模型能在局限的硬件资源上以更好的性能完成实时交通标志检测。

#### 5.1 数据集预处理

本文从 TT100K 中人工筛选出包含重要路面信息、且数量多于 100 张的 25 类交通标志,从而防止后续模型出现过拟合的情况。

#### 5.2 YOLOv5

YOLOv5 (You Only Look Once Version 5)<sup>[20]</sup>属于一阶段的目标检测算法,其模型结构如图 6 所示。在开源版本中, YOLOv5 共有 YOLOv5x、YOLOv5l、YOLOv5m、YOLOv5s 和 YOLOv5n 五个版本。其中 YOLOv5n 是深度与宽度最精简的网络,考虑到模型后续将部署在嵌入式平台上进行实时推理,因此本文选用模型体积较小的 YOLOv5n 作为基础模型,其预训练权重大小仅 3.6 MB。

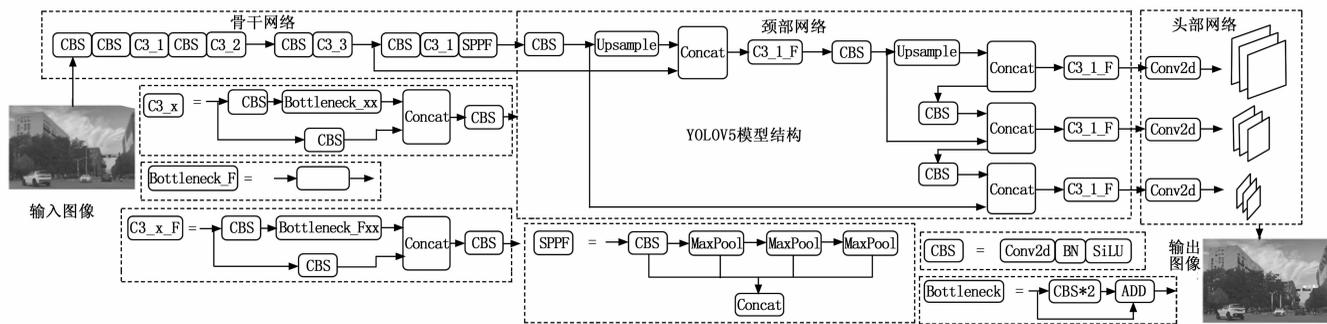


图 6 YOLOv5 网络结构

训练模型使用的平台为 Windows11 操作系统, 使用 CUDA10.0 和 cuDNN7.64 加速训练, 编程语言为 python3.6, 网络开发框架为 Pytorch1.6。

YOLOv5 是基于回归的目标检测算法, 把识别作为一个回归问题来解决, 提高识别速度, 因此能够从一张图片中识别出多种不同类别的物体, 计算物体尺寸信息以及所占图片位置, 并且绘制识别框。除此以外, 该算法还引入了迁移学习的概念, 对于数据集的样本数量要求大幅降低, 能够适应更多场景。

该算法网络模型结构可以分成输入端、骨干网络、颈部网络、预测输出端。

### 5.2.1 输入端

YOLOv5 的输入端的操作包含自适应锚框计算、自适应图像填充缩放, 以及 Mosaic 数据增强。

自适应锚框计算中, 算法读取训练集的图片以及检测框的宽、高, 利用 K-means 聚类算法对所有检测框聚类分析得到锚框, 在初始锚框的基础上输出预测框与真实框进行比较, 并计算差距、反向计算、迭代更新网络参数, 以此解决多尺度问题和多目标检测问题。

Mosaic 数据增强通过随机缩放、随机缩减和随机排列拼接四幅图片。每一张图片都有其对应的框, 将四张图片拼接之后就获得一张新的图片, 同时也获得这张图片对应的框。接着将这张新的图片传入到神经网络进行训练, 在批标准化计算时, 可以一次获得四张图片的数据, 使数据可以分批处理, 然后再进行排序, 在仍旧保持着较低的复杂度的情况下扩大数据集容量, 丰富了检测物体的背景和小目标, 有利于 GPU 运算处理<sup>[21]</sup>。

自适应图像填充缩放的作用是有效利用感受野信息。在目标识别任务中, 如果输入图片的尺寸大小不统一, 会降低实验的正确率。若只使用 OpenCV 中内置函数改变图片大小可能会导致图片失真、压缩过度, 以至于失去部分特征, 所以检测的时候使用信箱来统一尺寸大小, 采用相同的长宽的收缩比例, 有效利用图像信息。

### 5.2.2 骨干网络

YOLOv5 的骨干网络主要是用来提取图像特征的网络, 它的主要作用是将原始的输入图像转化为多层特征图, 以

便后续的目标检测任务使用。本文所使用的 YOLOv5n 使用的骨干网络是 CSPDarknet, 能够在保证较高检测精度的同时, 尽可能地减少内存占用和计算量。主要包含 Focus、CSP 和空间金字塔模块 SPP 结构。Focus 对输入图像进行切片操作, 减少模型层数, 提高运行速度。CSP 网络结构由 CBL 模块、Resuit 模块、Concat 通道融合结构、Leaky\_Relu 激活函数组成。CBL 模块由卷积模块、批标准化模块、激活函数构成。空间金字塔模块 SPP 可以增大特征图的感受野。

### 5.2.3 颈部网络

颈部网络采用了如图 7 所示的特征金字塔网络 FPN、路径聚合网络 PAN。FPN 做自顶向下的部分, 主要是通过上采样以及更粗粒度的特征图融合以实现不同层次特征的融合, 而 PAN 做自下向上的部分则是通过一个卷积层来融合不同层次的特征图。通过上采样和下采样的操作将来自不同层次的特征图融合在一起, 生成多尺度的特征金字塔。保证了对不同尺寸的图片的准确预测, 减少对小目标信息的损失。

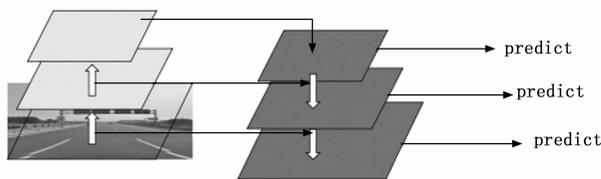


图 7 FPN 结构

### 5.2.4 预测输出端

预测输出端主要用来对特征金字塔进行目标检测的部分, 采用了多层级特征融合的方法, 首先骨干网络输出的特征图将经过一个卷积模块降维通道数和缩放特征图, 再融合不同层级的特征图, 得到更加丰富的特征信息, 从而提高检测性能。预测输出端还使用了一些技巧来进一步提升检测精度, 比如 GIoU loss、Mish 激活函数和多尺度训练等。

总的来说, YOLOv5 在各个模块上的设计都充分考量了速度和精度之间的平衡, 使得它在目标检测任务中有出色的表现。

### 5.3 改进方案

由于本系统的雨雾天交通标志检测任务属于在嵌入式平台上的小目标检测任务，因此 YOLOv5 模型改进主要从小目标检测优化与推理加速两个方面进行。

雨雾天交通标志检测任务属于小目标检测任务，因此本文先对雨雾交通场景图通过轻量级网络 AOD-NET 进行了去雾预处理。另外，本文利用 K-means++ 对锚框选取方法进行优化。除此以外，为了符合实际场景的要求，本系统需要实时检测目标从而提醒驾驶员，因此要在保证模型性能的情况下提高模型推理速度，本文对 YOLOv5 模型的骨干网络结构进行了改进，并在结束训练与测试后对模型进行了剪枝与量化的操作，最大化提升模型推理速度，最终在嵌入式平台上表现良好。

#### 5.3.1 去雾预处理

在雨雾天气中，由于雾霾、雨水等因素的影响，交通标志可能会被遮挡、模糊或失真，对交通标志检测任务的准确性和可靠性造成极大影响。因此，本文使用 AOD-NET 轻量级去雾预处理在极小的时间代价下改善图像的特征。AOD-NET 可以去除雾霾、雨水等因素带来的图像噪声和失真，提高图像的质量和清晰度。这使得 YOLOv5 模型更容易检测和识别交通标志。雨雾天气中的图像因素会影响交通标志的特征表示，从而影响交通标志检测的准确性。去雾预处理可以极大地减轻影响，改善图像特征，使得后续交通标志检测模型更易于学习和识别交通标志的特征。

本文在 TT100K 数据集及其加雾数据集上，对比了直接训练测试与先去雾后训练测试的 YOLOv5n 原始模型，其对比图如图 8 所示。



图 8 未去雾训练测试与去雾训练测试

其具体性能指标如表 2 所示。

表 2 去雾训练与测试效果

训练与测试方式	mAP/%
有雾图像直接训练与测试	56.7
去雾图像间接训练与测试	69.1

容易看出，在输入网络前进行去雾预处理是有必要的。

#### 5.3.2 锚框与骨干网络选取与对比

锚框是用于检测目标物体的重要组成部分，通过将图像分成多个网格单元，每个单元预测一组锚框的大小和位置，然后将预测结果与真实目标进行匹配，从而完成目标

检测。先验锚框的尺寸与数据集越贴合，预测也将会更加准确，并且模型更容易收敛。由于被检测物体交通标志属于小目标的范畴，因此需要对官方的锚框预设数据进行调整，使其更适应小目标检测的需求。本文利用改进后的 K-means 算法即 K-means++ 算法，将所有训练集中的目标框进行簇数为 3 的聚类，选取 3 个聚类中心锚框值为先验锚框尺寸，以得到一组具有代表性的先验锚框尺寸，从而更好地适应小目标检测的需求。

K-means++ 算法通过轮盘赌算法选取了 K 个聚类中心，再计算各锚框与聚类中心的欧氏距离，依据欧氏距离大小对锚框进行聚类，聚类完成后针对每个聚类所得的锚框簇再次计算簇中心，作为下一次聚类的中心，迭代以上操作，直到聚类中心不再改变。表 3 展示了利用 K-means++ 算法挑选出的先验锚框在不同特征图上的具体尺寸大小。

表 3 改进先验锚框尺寸

特征图尺寸	先验锚框尺寸		
小	(9×9)	(11×12)	(15×16)
中	(19×21)	(25×27)	(32×34)
大	(44×44)	(66×67)	(98×90)

骨干网络选取上，在保证模型在较高检测准确率的情况下，为了可以获得更快的推理速度，本文选取了 MobileNetV2 与原有的 CSPDarknet 进行对比。MobileNetV2 是一种轻量级的卷积神经网络，它可以在保持较高的准确率的同时大幅减小模型参数和计算量。MobileNetV2 模型相较于其他骨干网络，如 ResNet 等，模型参数较少，计算量较小，使得 MobileNetV2 作为 YOLOv5 骨干网络的模型在硬件资源有限的场景下更加实用，如在嵌入式设备、移动端设备等。另外，MobileNetV2 模型结构简单，可扩展性强，修改其结构较为轻松，例如添加或删除卷积层、修改卷积核的数量和大小等。这使得 MobileNetV2 模型更容易地适应不同的应用场景和数据集。

本文训练了骨干网络为 CSPDarknet 的 YOLOv5s 模型、骨干网络为 CSPDarknet 的 YOLOv5n 模型与骨干网络为 MobileNetV2 的 YOLOv5n 模型，在嵌入式平台 Jetsonnano 上进行对比实验，测试结果如表 4 所示，

表 4 不同网络性能与大小对比

网络模型	参数量	GFLOPs	mAP/%	FPS
YOLOv5s+CSPDarknet	7.131 490 M	16.1	76.5	7.94
YOLOv5n+CSPDarknet	1.820 050 M	4.3	69.1	15.50
YOLOv5n+MobileNetV2	0.226 882 M	0.9	63.7	15.38
YOLOv5n+ShuffleNetV2	1.237 625 M	3.1	68.9	17.89

经过实验对比，发现用来替换原有骨干网络的主流网络 MobileNetV2 虽然参数量较小，但由于有较多残差连接的结构，在 FPS 指标上与原有的 YOLOv5n 几乎持平，并且在 mAP 指标方面仍难以超越 YOLOv5n，因此 Mobile-

NetV2 不适用于后续嵌入式平台的部署。而 ShuffleNetV2 虽然模型参数多于 MobileNetV2, 但实际计算时 FPS 超过了 MobileNetV2, 且 mAP 也几乎与原先的 CSPDarknet 持平, 性能与速度都较为可靠。因此, 使用 ShuffleNetV2 作为 YOLOv5n 的骨干网络。

### 5.3.3 模型剪枝

为了进一步提高 YOLOv5 模型在 Jetsonnano 上的效率, 使用模型剪枝技术处理已经训练完成的改进 YOLOv5n 模型。采用通道剪枝技术, 通过稀疏化训练, 将对输出结果影响较小的通道剪去。在不损失过多精度的前提下, 尽可能地加快模型推理速度, 更好地满足实时运算的需求。

YOLOV5n+ShuffleNetV2 模型中的 BN (Batch Normalization) 层通过对每个小批次的数据进行归一化处理, 对输入数据进行白化, 进而加速网络学习过程, 并且减轻了对超参数的依赖性, 提高了模型的泛化能力。BN 层往往可以加速模型的收敛、抑制过拟合和提升模型精度。BN 层具体计算公式如下:

$$\begin{cases} \mu_{\beta} = \frac{1}{m} \sum_{i=1}^m x_i \cdot y_i \\ \sigma_{\beta}^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_{\beta})^2 \\ \hat{x}_i = \frac{x_i - \mu_{\beta}}{\sqrt{\sigma_{\beta}^2 + \epsilon}} \\ y_i = \gamma \hat{x}_i + \beta = BN_{\gamma, \beta}(x_i) \end{cases} \quad (5)$$

其中:  $\mu_{\beta}$ 、 $\sigma_{\beta}$  分别为批处理数据的均值与标准差,  $x_i$ 、 $y_i$  分别为 BN 层的输入数据与输出数据,  $\gamma$  与  $\beta$  分别为缩放因子与移位因子, 均为可学习的因子。缩放因子  $\gamma$  衡量了输入对输出的影响程度,  $\gamma$  越小, 则通道输入对后续通道输出影响很小。

本文基于 BN 层  $\gamma$  系数对 YOLOV5n+ShuffleNetV2 模型进行剪枝, 根据先验知识选取稀疏化率在 0.005 至 0.000 05 之间进行训练, 在不同稀疏率下, mAP 变化趋势如图 9 所示。

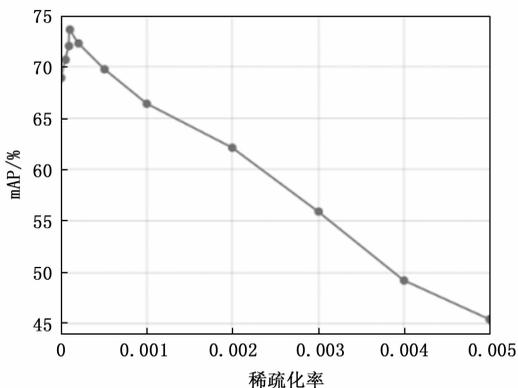


图 9 不同稀疏率下模型 mAP 变化

模型 mAP 在稀疏化率为 0.000 1 时表现最好, 为 73.6%, 而稀疏化率在超过 0.000 1 后, 模型 mAP 值急剧

下降。因此选择稀疏化率为 0.000 1 时的模型进行剪枝。删除绝对值超过剪枝率对应阈值的权重, 同时验证模型性能, 具体实验结果如表 5 所示。

表 5 不同剪枝率下的实验结果

剪枝率	mAP / %	参数量
0	73.6	1.24 M
0.3	70.9	0.86 M
0.4	68.1	0.60 M
0.5	67.0	0.47 M
0.6	61.8	0.36 M
0.7	52.8	0.20 M

具体剪枝前后实验结果对比如表 6 所示, 剪枝后网络精度虽然有小幅度的下降, 但推理速度相比剪枝前提高了 59.2%。

表 6 网络剪枝前后实验对比结果

网络	GFLOPs	参数量	mAP / %	FPS
剪枝前	3.1	1.24 M	68.9	17.89
剪枝后	1.7	0.47 M	67.0	24.68

## 6 系统测试结果与分析

### 6.1 系统本地运行环境

在 AOD-NET 与改进 YOLOv5 训练与测试完成后, 本文将这两个模型部署在了嵌入式平台 Jetson nano 中, 并编写主程序将湿度识别模块、去雾模块、交通标志检测模块和蓝牙语音播报模块串联, 形成完整的系统。由于车内无法放置显示屏演示, 因此选择了在室内以读取与摄像头相同格式行车记录仪视频的方式进行演示。系统本地的运行环境如图 10 所示。



图 10 系统运行环境

系统的测试步骤如下:

1) 配置 Jetson nano 环境与调试。本系统在运行前需要先安装 OpenCV 图像处理库、Pytorch 深度学习框架并传入模型参数, 安装传感器并通过 GPIO 进行调试, 直到可以正确读取大气湿度并传入 Python 进程。

2) 读取行车视频, 运行主程序。实际测试中, 各个功能运行流畅, 交互无卡顿, 语音播报清晰, 可靠性较高,

其中开启摄像头后检测模型的 FPS 达到了 17.78。实际检测效果如图 11 所示。



图 11 系统检测过程

综上所述,系统测试符合实时推理、准确识别、成功播报的预期,有着实际的应用价值。

## 6.2 模型对比与分析

本文的改进模型采用的是更换骨干网络后完成稀疏化训练的 YOLOv5n 模型,并在此模型前采用 AOD-NET 进行去雾。通过调整仿真环境下的雾气浓度和图片实际分辨率,在上述完成配置环境的嵌入式平台 Jetson nano 上,重复预测了加雾后 TT100K 数据集中的交通标志,并与数据集标签进行对比,计算 mAP 值。同时,在实际行车记录仪视频中,在嵌入式平台中测试 AOD-NET+YOLOv5n 与本文改进模型的 FPS。具体实验结果如表 7 所示。

表 7 YOLOv5n 与本文改进模型实验对比结果

网络	mAP/%	FPS
AOD-NET+YOLOv5n	67.2	12.21
本文改进模型	65.8	17.78

在雾气不断变化、图片分辨率抖动的情况下,本文的改进模型也能与 YOLOv5n 模型保持相近的 mAP,而每秒运行图片帧数 FPS 则大幅提升,从而可以更及时地处理实时信息,满足了实际中实时行车辅助驾驶的需要。

## 7 结束语

本文设计并开发了一种基于机器视觉的雨雾天气语音辅助驾驶系统,能在雨雾天气和正常天气两种天气下依靠机器视觉检测前方路面标志牌,将 AOD-NET 去雾算法与改进的 YOLOv5 模型相结合,在多次对比实验的基础上验证了检测的准确性,同时也利用了模型剪枝技术,提高了模型速度,使之在嵌入式平台 Jetson nano 上得以实时推理运行。处理检测结果后,有序地通过车载蓝牙音箱向驾驶员播报前方交通标志信息,高效准确地为驾驶员提供丰富的路面信息,可以有效地减少交通事故发生概率。在后续工作中,可以围绕更多天气状况,制定更多的应对策略,从而提高系统面对各种天气时的鲁棒性。

### 参考文献:

[1] 樊星,沈超,徐江,等.基于级联端到端深度架构的交通标志识别方法[J].计算机测量与控制,2019,27(4):143-148.

[2] 李晓琳,庞保孟,曹银杰,等.基于微控制器改进 SqueezeNet 交通标志识别的研究[J].计算机测量与控制,2020,28(5):88-92.

[3] 黄桥,胡绍林,张彩霞,等.基于改进 SSD 的道路交通标志检测[J].计算机测量与控制,2021,29(10):60-65.

[4] 王林,张文卓.一种融合注意力机制与上下文信息的交通标志检测方法[J].计算机测量与控制,2022,30(3):54-59.

[5] 张玥,张琦,李珣,等.雾霾图像增强算法对目标检测性能影响研究[J].计算机测量与控制,2019,27(1):41-46.

[6] 乔敏,孙国强.基于维纳复原的道路限速交通标志检测[J].软件导刊,2020,19(5):234-237.

[7] 张宏宇.基于改进 Faster-RCNN 的交通标志检测[D].西安:长安大学,2022.

[8] 朱开,陈慈发.基于 YOLOv5 的雾霾天气下交通标志识别[J].电子测量技术,2023,46(8):31-37.

[9] 院老虎,常玉坤,刘家夫.基于改进 YOLOv5s 的雾天场景车辆检测方法[J].郑州大学学报(工学版),2023,44(3):35-41.

[10] 郑楚伟,林辉.基于 Swin Transformer 的 YOLOv5 安全帽佩戴检测方法[J].计算机测量与控制,2023,31(3):15-21.

[11] 韦越,陈世超,朱凤华,等.基于稀疏正则化的卷积神经网络模型剪枝方法[J].计算机工程,2021,47(10):61-66.

[12] 罗中杉,李健,刘丹丹.Jetson Nano 平台下的 AI 送餐系统设计[J].软件导刊,2022,21(12):128-132.

[13] 刘明旺.基于 YOLOv3 的国内交通标志识别及嵌入式实现[D].海口:海南大学,2020.

[14] 周宇,杨国平,刘森.基于 Jetson Nano 和 OpenCV 的智能门锁系统实现[J].智能计算机与应用,2022,12(2):120-122.

[15] E J MCCARTNEY. Optics of the atmosphere: scattering by molecules and particles [J]. John Wiley and Sons, 1976: 123-129.

[16] LI B, PENG X, WANG Z, et al. An all-in-one network for dehazing and beyond [J]. arXiv preprint arXiv: 1707.06543, 2017.

[17] HE K, JIAN S, FELLOW, et al. Single Image Haze Removal Using Dark Channel Prior [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2011, 33(12): 2341-2353.

[18] 孙靖凯.基于改进的 AOD-Net 和 YOLOv5 的雾天车辆行人检测算法[D].哈尔滨:哈尔滨理工大学,2022.

[19] 田莹,王亮,丁琪.基于深度学习的图像语义分割方法综述[J].软件学报,2019,30(2):440-468.

[20] YANG G, FENG W, JIN J, et al. Face mask recognition system with YOLOV5 based on image recognition [C] //2020 IEEE 6th International Conference on Computer and Communications (ICCC). IEEE, 2020: 1398-1404.

[21] 褚文杰.基于 YOLOv5 的坦克装甲车辆目标检测关键技术的研究[D].北京:北京交通大学,2021.