

自动驾驶目标检测算法不确定性建模研究

姜彦吉^{1,2}, 张 潇^{1,2}, 董 浩^{2,3}, 郭佳鑫², 刘大千¹

(1. 辽宁工程技术大学 软件学院, 辽宁 葫芦岛 125105; 2. 优策(江苏)安全科技有限公司 OpenSafe 实验室;
3. 清华大学 苏州汽车研究院, 江苏 苏州 215100)

摘要: 针对雨、雪、雾等不良天气对自动驾驶视觉感知系统准确性和可靠性造成的严峻挑战, 提出一种基于YOLOv11目标检测算法的不确定性建模方法。该方法采用拉普拉斯分布建模预测边界框的不确定性, 并利用信息熵量化分类任务的不确定性, 将量化结果纳入重新设计的预测边界框损失函数和分类损失函数中, 使模型能够自适应调整对边界框预测精度和分类置信度的关注。通过在CADC、BDD100K和自建数据集上的实验验证, 本文方法相较于基线模型在mAP@0.5指标上分别提升了9.3、5.2和8.6个百分点。实验结果表明, 该方法有效提高了算法在不良天气条件下的鲁棒性和准确性, 显著降低了漏检误检的概率, 提升了检测精度和预测结果的可靠性。

关键词: 自动驾驶; 目标检测; YOLOv11; 不确定性建模; 拉普拉斯分布

DOI: 10.11907/rjtk.251250

扫描二维码阅读全文: 

中图分类号: TP391.41

文献标识码: A

文章编号: 1672-7800(2026)007-0169-10

Research on Uncertainty Modeling of Autonomous Driving Object Detection Algorithm

JIANG Yanji^{1,2}, ZHANG Xiao^{1,2}, DONG Hao^{2,3}, GUO Jiaxin², LIU Daqian¹

(1. College of Software, Liaoning Technical University, Huludao 125105, China; 2. OpenSafe Lab, Utcer(Jiangsu)Security Technology Co., Ltd.; 3. Suzhou Automotive Research Institute, Tsinghua University, Suzhou 215100, China)

Abstract: This paper proposed an uncertainty modeling method based on the YOLOv11 object detection algorithm to address the challenges posed by rainy, snowy, and foggy weather to the accuracy and reliability of autonomous driving visual perception systems. The method used a Laplace distribution to model the uncertainty of predicted bounding boxes and employed information entropy to quantify the uncertainty of classification tasks. These quantified uncertainties were incorporated into redesigned bounding box loss functions and classification loss functions, enabling the model to adaptively adjust its focus on bounding box prediction accuracy and classification confidence. Experimental validation was conducted on the CADC, BDD100K, and a self-built dataset, demonstrating that the proposed method achieves improvements of 9.3%, 5.2%, and 8.6% in mAP@0.5 compared to baseline models. The experimental results show that the method significantly improves the robustness and accuracy of algorithms under adverse weather conditions, reduces the probability of missed or false detections, and enhances detection precision and prediction reliability.

Key Words: autonomous driving; object detection; YOLOv11; uncertainty modeling; Laplace distribution

0 引言

近年来,自动驾驶技术取得了显著进展,但智驾系统

的表现仍面临着动态复杂交通驾驶环境带来的诸多挑战,包括感知、规划决策和执行控制^[1-2]。其中,目标感知算法的可靠性对于智驾的决策过程至关重要。在雨、雪、雾等不良天气条件下,视觉传感器表面覆盖的雨滴和雪花,以

收稿日期: 2025-04-09

基金项目: 国家自然科学基金青年基金项目(62303477); 广东省科技创新战略专项市县科技创新支撑项目(STKJ2023071); 葫芦岛市科技计划项目(2023JH(1)4/02b); 浙江省自然科学基金面上项目(LMS25G010003)

作者简介: 姜彦吉(1985-), 男, 博士, 辽宁工程技术大学教授、硕士生导师, 研究方向为自动驾驶感知、预期功能安全; 张潇(2000-), 女, 辽宁工程技术大学硕士研究生, 研究方向为计算机视觉、自动驾驶感知; 董浩(1981-), 男, 博士, 优策(江苏)安全科技有限公司高级工程师、硕士生导师, 研究方向为预期功能安全; 郭佳鑫(1993-), 男, 优策(江苏)安全科技有限公司工程师, 研究方向为自动驾驶测试; 刘大千(1992-), 男, 博士, 辽宁工程技术大学教授、硕士生导师, 研究方向为智能无人系统、图像与视觉信息计算。本文通讯作者: 姜彦吉。

及雾气的散射效应,都会降低图像的对比度,导致物体边缘变得模糊。这些因素会损害目标检测算法对关键信息的识别,进而增加漏检和误检的风险,如图1所示。其中,蓝色框标记了漏检或误检物体所在位置,框内黑

色字体显示了该物体的正确类别。因此,评估算法预测结果的不确定性程度有助于识别感知系统在不同恶劣天气下的安全边界,从而显著提升系统的安全性和可靠性。




Fig. 1 Examples of YOLOv11's missed and false detections in adverse weather conditions

图1 YOLOv11在不良天气条件下的漏检与误检示例

目标检测算法经历了从基于特征的方法到深度学习方法的转变。早期的两阶段检测器如R-CNN^[3]、Fast R-CNN^[4]和Faster R-CNN^[5],虽然检测精度较高,但在处理大规模数据和实时性方面存在局限性。随着一阶段检测器如SSD (single shot multibox detector)^[6]、YOLO (you only look once)^[7]和Efficient Det^[8]的出现,目标检测算法在推理速度和效率上取得了显著提升,但这些算法在不良天气条件下的表现仍然不够稳定。

此外,对于深度学习算法不确定性的研究也在不断推进。Gal等^[9]在2016年提出了MC-Dropout (monte carlo dropout),在不改变原模型结构的基础上添加dropout层,近似估计网络权重的后验分布,实现了对深度神经网络认知不确定性的估计。但该方法需要多次前向传播,计算成本高,且由于dropout的随机性,可能导致预测结果的方差较大,影响模型稳定性。Lakshminarayanan等^[10]在2017年提出的Deep Ensemble,通过集成同分布模型并进行随机采样的方法来估计预测结果的不确定性,能够提供高质量的不确定性预测,但其集成多个模型的方法在实际应用中带来了巨大的计算开销。

近年来,越来越多人关注自动驾驶目标检测器的安全性和可靠性^[11]。文献[12]提出一种改进的非极大值抑制技术,通过拟合狄拉克分布估计定位不确定性。Choi等^[13]在YOLOv3模型中引入高斯分布建模定位不确定性,提高了目标检测的准确性。文献[14]使用MCD方法对预期功能安全(SOTIF)场景下的YOLOv3目标检测算法进行不确定性建模,并分析了算法的不确定性与置信度之间的关系。文献[15]提出了一种基于激光雷达点云的生成模型来估计目标检测中边界框标签的不确定性,并通过引入Jaccard IoU (JIoU)这一新评估指标,解决了现有目标检测数据集中标签不确定性未被充分考虑的问题,从而提高了自动驾驶领域目标检测算法的准确性和鲁棒性。Gasperi-

ni等^[16]提出了一种无需采样的方法估计自动驾驶目标检测器的不确定性,能够在保持实时性的同时提供高质量的不确定性建模。然而,现有研究中极少有专注于在不良天气条件下进行目标检测不确定性建模的工作,尤其是在数据分布呈现重尾特性的情况下,现有方法难以准确建模定位和分类不确定性。因此,这一问题亟待进一步研究和解决。

YOLOv11算法作为目前较为先进的目标检测算法之一,虽然在精度和效率上相比早期版本有显著提升,但其在设计时主要针对良好天气条件下的图像数据进行优化,对于不良天气下数据分布的重尾特性适应性较差,易出现漏检和误检情况。针对上述问题,本文提出了一种针对YOLOv11算法在不良天气下检测结果不确定性的建模方法。本文的创新性工作如下:

(1)采用拉普拉斯分布对YOLOv11的目标物体的定位不确定性进行建模,以适应不良天气下数据的重尾特性。

(2)通过计算信息熵,量化模型对每个样本分类结果的不确定性,从而反映模型对其分类结果的确定程度,提高模型的可靠性。

(3)将量化的不确定性纳入损失函数,以实现模型的校准,从而解决不良天气易出现定位不准确、赋予检测物错误的标签和过高置信度的问题,提高了模型的鲁棒性,极大程度上降低了由于误检和漏检导致的自动驾驶车辆错误决策,从而减少了事故风险。

1 不确定性表征

1.1 定位不确定性表征

本文YOLOv11采用轻量级结构和优化策略,平衡了速度与精度,适用于工程中对实时性要求高的应用场景。然而,在复杂环境或噪声干扰下,其传统边界框预测方法容

易产生定位误差。目前的研究多采用高斯分布来估计定位不确定性。但高斯分布对异常值敏感, 这种方法在噪声干扰严重的自动驾驶场景中, 难以准确描述数据分布, 导致不确定性建模存在偏差。高斯分布的概率密度函数如式(1)所示。

$$f(x|\mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (1)$$

高斯分布对异常值非常敏感, 这是由于其平方项 $(x - \mu)^2$ 在计算时会放大偏离均值的值, 导致异常值对均值 μ 和方差 σ^2 的影响较大。

针对这一问题, 本文提出采用拉普拉斯分布对YOLOv11的定位不确定性进行建模。拉普拉斯分布的概率密度函数如式(2)所示。

$$f(x|\mu, b) = \frac{1}{2b} e^{-\frac{|x-\mu|}{b}} \quad (2)$$

相较于高斯分布, 拉普拉斯分布的尾部衰减由绝对值项 $|x - \mu|$ 控制, 因此其衰减是线性的, 而高斯分布的衰减是指数平方形式。这样的特性使得拉普拉斯分布的尾部衰减较慢, 具有重尾特性, 如图2所示。这种特性允许它在尾部赋予较高的概率密度, 极端值不会被视作异常, 而是被视为分布的一部分。因此, 整体统计量在计算时不会因为少数极端值而发生显著变化, 能够更有效地捕捉极端值并为其不确定性建模, 从而为自动驾驶系统在不良天气条件下提供更稳健的定位不确定性建模。




Fig. 2 Comparison of probability density curves

图2 概率密度曲线对比

在目标检测算法中, 中心点和宽高 $[x, y, w, h]$ 格式未能充分考虑到预测边界框的定位不确定性(如尺度或方向)^[17]。因此, 将YOLOv11的预测边界框修改为基于中心点到上、下、左、右4个边框的距离 $[t, d, l, r]$, 具体计算如式(3)所示。

$$t = d = \frac{h}{2}, l = r = \frac{w}{2} \quad (3)$$

采用拉普拉斯分布函数对上述各分量进行建模, 建模后包含拉普拉斯参数的预测边界框为 $[\mu_t, b_t, \mu_d, b_d, \mu_l, b_l, \mu_r, b_r]$, 每

个预测边界框的各分量由一对 $[\mu, b]$ 表示。其中, μ 是该分量的期望, b 是拉普拉斯分布的尺度参数。

对每个预测边界框 j , 计算各分量的残差及其尺度参数 b , 如式(4)~式(5)所示。

$$r_{j,i} = |v_{j,i} - \hat{v}_{j,i}|, i \in \{t, d, l, r\} \quad (4)$$

$$b_{j,i} = \frac{1}{m} \sum_{d=1}^m r_{j,i}^{(d)} \quad (5)$$

其中, $v_{j,i}$ 、 $\hat{v}_{j,i}$ 、 $r_{j,i}$ 和 $b_{j,i}$ 分别表示第 j 个预测边界框的第 i 个分量的真实值、预测值、残差和不确定性, m 是用于估计的样本数量。

为了确保尺度参数在模型训练和推理过程中始终保持正值, 采用Softplus激活函数对预测边界框中各分量的尺度参数进行转换, 如式(6)所示。

$$b_{j,i} = \text{Softplus}(b_{j,i}) \quad (6)$$

其中, $\text{Softplus}(x) = \ln(1 + e^x)$, 相较于ReLU函数, Softplus函数提供了一个平滑、连续的转换, 这在训练过程中有助于梯度的稳定和传播。转换后的尺度参数不仅保证了概率分布的有效性, 而且通过其值的大小反映了边界框中各分量的不确定性。较大的 b 值意味着该分量的不确定性较高, 反之则意味着该分量的不确定性较低。

1.2 分类不确定性表征

YOLOv11通过在预测边界框上应用softmax函数来输出各个类别的概率, 这些概率通常被视为分类的置信度。然而, 在不良天气条件下, 图像对比度会显著降低, 导致图像中目标物体的特征变得不够清晰。这种情况下, 模型可能会产生过度自信的预测, 即给出高置信度的假阳性结果。即便对于最先进的目标检测器, 有效区分预测结果是真阳性还是假阳性, 仍然是一个挑战。因此, 本文提出了使用信息熵来量化模型分类的不确定性, 帮助理解模型在特定情况下的自信程度, 进而减少在不良天气条件下的假阳性预测, 如式(7)所示。

$$h = -\sum_{c=1}^C p_c \lg(p_c) \quad (7)$$

其中, p_c 是模型预测第 c 类的概率, h 是信息熵。信息熵的值越高, 表示模型对其分类决策的不确定性越大; 值越低, 表示不确定性越小, 模型对其预测结果越有信心。

2 基于不确定性的模型校准

原始的YOLOv11模型在边界框回归训练中采用了IoU损失函数。然而, 由于本文应用拉普拉斯分布对预测边界框各分量的不确定性进行建模, 因此需要设计一种新的预测边界框损失函数, 并在其中加入预测边界框中各分量不确定性的度量, 如式(8)所示。通过这种方式, 模型的输出不再是单一的确定性边界框, 而是一个概率分布。该分布能够反映在当前条件下预测边界框位置的可信程度, 模型在整个训练过程中都充分考虑了这一不确定性, 从而

优化了模型对被检测物体的定位能力,提升了定位的准确性。

$$L = \sum_{i \in \{t, d, l, r\}} (\lg(2b_i) + \frac{|x_i - \mu_i|}{b_i}) \quad (8)$$

其中, x_i 是真实边界框的各个分量, μ_i 是预测边界框的各个分量, b_i 表示预测边界框各分量的不确定性。

然而, 不确定性 b_i 若缺乏适当的约束, 可能会导致数值不稳定, 尤其在数据分布不均或某些类别样本稀缺的情况下。例如, 当 b_i 值过低时, 对数项 $\lg(2b_i)$ 会变得异常大, 影响数值稳定的同时, 也会导致损失函数无限增大, 给模型的优化过程带来困难。为避免上述问题, 本文提出对不确定性 b_i 进行 L2 正则化处理, 如式(9)所示。

$$L_{bbox} = L + \lambda \sum_{i \in \{t, d, l, r\}} b_i^2 \quad (9)$$

其中, λ 是正则化系数。通过正则化 b_i , 可以确保 b_i 不会接近于 0, 从而维持计算的稳定性。此外, 模型在训练过

程中对于不确定性的估计会更加谨慎, 有助于提高模型在未见数据上的泛化能力。

对于分类损失, 本文将表征分类不确定性的信息熵加入到原有的分类损失函数中, 如式(10)所示。这种方式可以提高模型对分类不确定性的敏感度, 避免模型因过度自信而导致错误决策。

$$L_{cls} = L_{orig} + \beta \cdot h \quad (10)$$

其中, L_{orig} 表示 YOLOv11 原始的损失函数, 即交叉熵损失函数, β 是平衡原始损失和信息熵的超参数。本文保留了 YOLOv11 原始的分布焦点损失的计算方式。修改后的总损失函数可以进一步表示如式(11)所示。

$$L_{total} = L_{bbox} + L_{cls} + L_{dfl} \quad (11)$$

其中, L_{bbox} 是本文提出的新的预测边界框损失函数, L_{cls} 表示分类损失, L_{dfl} 表示分布焦点损失。本文方法的总体流程如图 3 所示, 系统地展示了从不确定性表征到模型校准与评估的完整流程。




Fig. 3 Overall flowchart

图3 总体流程图

3 实验结果与分析

3.1 数据集

本文基于加拿大不利驾驶条件数据集 (canadian adverse driving conditions dataset, CADC)^[18]、BDD100K^[19] 自动驾驶数据集和自建数据集, 验证本文提出的不确定性建模及模型校准方法的有效性。

CADC数据集是首个专注于下雪天气条件下真实世界驾驶数据的公共数据集, 采集于加拿大滑铁卢地区冬季。该数据集包含 56 000 张相机图像、7 000 次 LiDAR 扫描、75 个场景和 10 个注释类信息。该数据集提供的是适用于 3D 目标检测的标注形式, 为此, 本文对这些标签进行了处理, 将其统一转换为 2D 标注形式, 并进行了人工校正。

BDD100K数据集是由加州大学伯克利分校 AI 实验室发布的一个大规模、多样化的自动驾驶视频数据库, 采集于美国不同地区, 包括不同时间、不同天气条件 (晴天、阴天、雨天以及白天和晚上) 和各类驾驶场景, 涵盖 100 000 张 1 280×720 的图像。在本文中, 随机选取部分图像按照 7:2:1 的比例将其划分为训练集、验证集和测试集。该数据集的标注格式为 JSON 文件, 提供了丰富的信息, 如场景、天气、时间和对象的边界框及其属性等。

此外, 为了进一步验证方法的泛化能力, 本文构建了一个包含 12 568 张 4K 分辨率图像的数据集。该数据集使用 GoPro 10 Black 相机, 在中国江苏、浙江、吉林、辽宁等多个省份的不同路段采集, 涵盖了雨、雪、雾等多种不良天气场景。数据集中的图像按照天气条件进行分类和标注, 便于验证本文提出的方法。图 4 展示了自建数据集中的部分示例图像。




Fig. 4 Examples of self built dataset
图4 自建数据集示例

3.2 评价指标

在任务中,误检和漏检问题较为突出,因此通常使用召回率(recall)、精度(precision)以及平均精度均值(mean average precision, mAP)作为评估标准。本文采用IoU阈值为0.5时的评估结果(mAP@0.5)。同时,模型的大小、计算开销和推理速度也是评估的重要因素,通常采用参数量(parameters)、每秒千兆浮点运算量(floating point operations per second, GLOPs)和每秒帧数(frames per second, FPS)进行衡量。召回率、精度和平均精度的计算公式如式(12)~式(14)所示。

$$Recall = \frac{TP}{TP + FN} \quad (12)$$

$$Precision = \frac{TP}{TP + FP} \quad (13)$$

$$mAP = \frac{\sum_{i=1}^N AP_i}{N} \quad (14)$$

其中,TP(true positive)表示真正例,即模型正确预测为正例的样本数量。FN(false negative)表示假负例,即模型错误地将正例预测为负例的样本数量。FP(false positive)表示假正例,指模型错误地将负例预测为正例的样本数量。AP是通过计算Precision-Recall曲线下的面积所得结果,N为类别数目。

3.3 实验设置

本文模型的训练与测试均在配置 GeForce RTX 4090 GPU 的平台上进行。输入图像的尺寸统一设置像素为640×640,训练过程中采用的批量大小(batch size)为12,训练周期(epoch)为300,采用Adam优化器。在CADC、BDD100K和自建数据集上进行实验时,初始学习率和超参数 λ, β 设置如表1所示。表中同时展示了当不同参数在各自数据集上调整±50%时,模型性能(mAP@0.5)的变化趋势(↑表示提升,↓表示下降),从而揭示了参数的敏感性。

Table 1 Learning rate, hyperparameter setting and sensitivity analysis

表1 学习率、超参数设置及敏感性分析

数据集	参数	取值	+50% 调整	-50% 调整	mAP@0.5 变化范围	敏感性等级
CADC	初始学习率	10-4	↓ 3.2%(震荡)	↓ 1.8%(收敛慢)	3%≤Δ<5%	高
	λ	0.01	↓ 2.1%	↑ 1.5%	1.5%≤Δ<3%	中
	β	0.5	↑ 0.7%	↓ 1.3%	1.5%≤Δ	低
BDD100K	初始学习率	10-3	↓ 6.5%(发散)	↓ 4.2%(停滞)	≥5%	极高
	λ	0.02	↓ 3.8%	↑ 2.9%	3%≤Δ<5%	高
	β	0.4	↑ 2.1%	↑ 1.6%	1.5%≤Δ<3%	中
自建数据集	初始学习率	10-4	↓ 4.7%(震荡)	↓ 3.1%(停滞)	3%≤Δ<5%	高
	λ	1.0	↑ 1.9%	↓ 5.3%(过拟合)	≥5%	极高
	β	0.8	↓ 2.5%	↓ 4.1%	3%≤Δ<5%	高

3.4 异常值鲁棒性对比实验

本文将基于CADC数据集,对高斯分布与拉普拉斯分布在异常值的鲁棒性进行对比实验。

首先,从CADC数据集中随机选取包含目标标注数据的集合,通过随机平移边界框中心坐标(偏移量 $\Delta x, \Delta y \sim \mathcal{U}(-50, 50)$ 像素)生成5%离群样本。随后,分别计算高斯分布(均值)和拉普拉斯分布(中位数)的最大似然估计(MLE),同时,计算估计值相对于真实标注的偏移量,如式(15)所示。

$$\Delta = \|\text{MLE} - \theta_{true}\|_2 \quad (15)$$

其中,Δ表示偏移量,MLE表示高斯分布或拉普拉斯分布的最大似然估计, θ_{true} 表示目标的真实位置。在本实验中,假设目标真实位置为原点,即 $\theta_{true} = 0$ 。

基于上述实验得出5%离群值污染下参数估计误差对比图,如图5所示。从图中可以看出,高斯分布估计误差为 12.0 ± 1.8 px,拉普拉斯估计误差为 4.4 ± 0.6 。实验结果表明,当存在5%离群值时,高斯分布参数估计的偏移量为拉普拉斯分布的2.7倍,说明拉普拉斯分布比高斯分布对异常值的鲁棒性更好。




Fig. 5 Comparison chart of parameter estimation errors under 5% outlier pollution

图5 5%离群值污染下参数估计误差对比图

3.5 不确定性建模质量评估

对于本文提出的不确定性建模方法,采用不确定性校准曲线来评估该方法分别在CADC数据集和BDD100K数据集上的建模质量。

通过 IoU 计算每个预测边界框与真实框之间的误差值,随后,将预测结果根据不确定性 b 的值进行分组,并计算每个组内实际误差的平均值。定位不确定性校准曲线如图 6 所示,其横轴表示定位不确定性 b ,纵轴表示对应的平均实际误差。从图中可以看出,基于

CADC 数据集和 BDD100K 数据集的不确定性校准曲线均呈递增趋势,随着定位不确定性 b 值的增加,实际误差也在增加。这表明模型的不确定性建模与实际误差较为一致,即本文方法具有较高的定位不确定性建模质量。




Fig. 6 Localization uncertainty calibration curve

图 6 定位不确定性校准曲线

分类不确定性校准曲线如图 7 所示。将模型的预测结果根据其不确定性进行分组,对于每个不确定性区间,计算该区间内预测正确的样本数与该区间内总样本数的比例。不确定性校准曲线的横轴表示分类不确定性 h ,纵轴代表对应的实际正确率。从图中可以观察到,基于 CADK 数据集和 BDD100K 数据集的不确定性

校准曲线均呈递减趋势,即随着分类不确定性 h 值的增加,实际正确率逐渐下降。这表明模型在面对高不确定性的预测时,正确率较低,准确反映出不确定性与实际结果之间的关联,验证了本文方法具有较高的分类不确定性建模质量。




Fig. 7 Classification uncertainty calibration curve

图 7 分类不确定性校准曲线

3.6 消融实验

为了全面验证各个组件对本文提出的不确定性建模方法的提升效果,在 CADK 数据集上对提出的方法进行了消融实验,以量化每个组件对检测精度和效率的贡献。表 2 展示了消融实验的详细结果。

实验结果表明,各个组件对模型性能提升均有显著作用。首先,在增加信息熵组件的情况下,相较于基线, $mAP@0.5$ 提升了 0.8 个百分点,这表明信息熵对分类准确性有明显提升作用。当仅使用高斯分布时, Recall 从

53.1% 降至 52.6%, 较基线降了 0.5 个百分点。然而,拉普拉斯分布在保持稳定检测方面表现更好, Recall 相较于基线提高了 3.1 个百分点,同时, $mAP@0.5$ 也提升了 1.7 个百分点, Precision 则从 68.2% 降至 67.5% (降低 0.7 个百分点)。其次,使用自定义损失函数后,基于高斯分布的方法在 Precision 上从基线 68.2% 提升至 74.1% (提高 5.9 个百分点)。随后,将自定义损失与拉普拉斯分布相结合后, Precision 相较于基线进一步提升至 75.6% (提高 7.4 个百分点)。最终,加入信息熵建模分类不确定性后,模型在 Re-

Table 2 Impact of each component on model performance							
表 2 各个组件对模型性能的影响							
高斯分布	拉普拉斯分布	信息熵	自定义损失	Recall /%	Precision /%	mAP@0.5/%	GFLOPs /G
				53.1	68.2	56.4	21.6
√				52.6	71.4	58.3	22.3
	√			56.2	67.5	58.1	22.4
		√		55.1	72.3	57.2	21.6
√			√	57.6	74.1	60.5	21.7
	√		√	59.3	75.6	62.8	22.5
		√	√	55.9	73.4	61.2	21.7
√		√		57.4	72.9	60.5	22.3
	√	√		58.6	73.1	62.3	22.4
√		√	√	59.4	73.5	62.9	22.4
	√	√	√	61.5	76.2	65.7	22.5

call、Precision 和 mAP@0.5 上分别达到 61.5%、76.2% 和 65.7%，较基线分别提升 8.4、8.0 和 9.3 个百分点。尽管 GFLOPs 从基线 21.6 G 增至最高 22.5 G，仅增长约 4.2%，但计算成本仍保持较低水平。综合来看，本文方法在显著提升检测性能的同时，兼顾了计算复杂度和推理效率。

3.7 算法性能比较

将本文方法与 SSD、Faster R-CNN 等目标检测算法在

CADC、BDD100K 和自建数据集上进行对比分析,对比算法均采用其官方发布的代码库进行训练和测试,以确保实验的准确性和可重复性。此外,为了全面评估本文方法的性能,本文不仅将其与现有的先进目标检测算法进行对比,还引入了 3 种不同的不确定性建模方法,并将其应用于 YOLOv11 中作为对照组进行比较研究。具体包括:基于高斯分布的不确定性建模,该方法借鉴了文献[14]中的研究成果,记作 Gaussian YOLOv11;MC-Dropout 方法,其模型构建方法借鉴文献[15]中的模型构建方法,采样次数为 5,记作 MCD YOLOv11;Deep Ensemble,通过集成多个独立训练的模型(在本实验中,模型数量为 3)进行不确定性建模,记作 DE YOLOv11。

表 3 展示了本文方法与其他目标检测算法在 CADK 和 BDD100K 数据集上的性能对比。结果表明,本文方法的性能显著优于其他算法,在两个关键数据集上的 mAP@0.5 分别达到了 65.7% 和 64.1%,相比基线 YOLOv11 模型提高了 9.3 和 5.2 个百分点。同时,在 Recall、Precision 和 mAP@0.5 各项指标上,本文方法均优于其他基于 YOLOv11 框架的不确定性建模方法。

Table 3 Performance comparison of object detection algorithms based on CADK and BDD100K										
表 3 基于 CADK 和 BDD100K 的目标检测算法性能比较										
方法	Params/M	GFLOPs/G	CADK				BDD100K			
			Recall /%	Precision /%	mAP@0.5 /%	FPS	Recall /%	Precision /%	mAP@0.5 /%	FPS
SSD	24.1	61.2	36.8	55.9	38.2	55	37.2	58.5	30.5	61
Faster R-CNN	136.8	370.0	33.1	51.3	34.6	23	35.5	52.6	48.4	30
Gaussian YOLOv3	62.1	67.3	32.6	52.0	33.4	37	39.7	59.8	40.1	43
EfficientDet	20.7	55.0	43.1	64.7	44.8	32	45.2	68.9	46.6	36
RetinaNet ^[20]	36.1	98.4	40.7	48.6	41.3	46	42.4	51.0	42.4	50
DETR ^[21]	41.0	225.0	44.5	46.1	38.6	28	45.6	48.1	40.2	32
YOLOv11	9.4	21.6	53.1	68.2	56.4	117	54.2	71.6	58.9	121
Gaussian YOLOv11	9.9	22.3	55.3	71.4	58.3	110	58.4	73.5	61.5	115
MCD YOLOv11	9.4	108.0	50.6	70.5	58.3	36	53.4	72.1	60.2	40
DE YOLOv11	28.2	64.8	58.2	73.1	61.4	21	57.5	74.3	62.3	25
本文方法	10.1	22.5	61.5	76.2	65.7	105	60.4	75.8	64.1	109

为了进一步验证本文方法的泛化能力,本文不仅在自建数据集上进行了泛化实验(如表 4 所示),而且在不同天气条件下对模型性能进行了全面评估(如表 5 所示)。实验结果表明,与基于 YOLOv11 的其他不确定性建模方法相比,本文方法在 mAP@0.5 上较基线提升了 8.6 个百分点,达到了 61.3%。同时,在轻雾、重雾、小雨、大雨、小雪和大雪等不同强度与类型的天气条件下,本文方法的 mAP@0.5 均高于其他方法。这种跨数据集、多环境条件下的性能一致性,充分表明本文方法在雪、雨、雾等多种环境条件下均能展现出良好的泛化能力和鲁棒性。

3.8 可视化结果和数值评估

图 8 展示了本文方法在不同训练周期中定位损失(L_{bbox})、分类损失(L_{cls})和总损失(L_{dfl})的收敛趋势。与基线

Table 4 Generalization experiments based on self-built datasets				
表 4 基于自建数据集的泛化实验				
目标检测算法	Recall /%	Precision /%	mAP@0.5/%	FPS
YOLOv11	53.6	67.0	52.7	110
Gaussian YOLOv11	57.4	66.5	54.1	102
MCD YOLOv11	52.1	62.4	51.3	30
DE YOLOv11	55.3	68.1	54.7	19
本文方法	58.5	72.7	61.3	97

YOLOv11 相比,本文方法在训练过程中实现了更快的收敛速度和更低的最终损失值。同时,整个训练过程中的损失曲线波动更小,表现出更强的稳定性。

由于缺乏对定位不确定性的直接监督,本文对预测边

Table 5 Performance comparison of different models under adverse weather conditions(mAP@0.5 /FPS)

表 5 不同模型在不良天气条件下的性能对比(mAP@0.5/FPS)

目标检测算法	轻雾	重雾	小雨	大雨	小雪	大雪
YOLOv11	54.1/115	41.6/105	49.8/112	45.2/107	48.3/113	43.6/109
Gaussian YOLOv11	55.8/112	46.5/98	53.4/109	49.0/100	53.2/110	48.7/101
MCD YOLOv11	53.7/38	46.8/27	50.4/36	48.3/28	50.3/36	45.8/28
DE YOLOv11	57.2/23	49.7/16	53.8/22	50.4/17	51.5/21	49.2/18
本文方法	63.9/104	55.4/93	59.7/102	58.7/95	59.2/104	57.1/97

界框每条边界的不确定性进行定性分析,示例如图 9 所示。图 9(a)、(b)和(d)由于受到雨、雾天气的影响,目标物体的边界模糊不清,在模糊的边界上,估计的不确定性高达 0.871。此外,在图 9(c)中,车辆受到道路标志牌的部分遮挡以及雪天对目标物体形状的影响,导致预测边界框的左边界与其实边界框之间存在较大偏差,因此图中两辆车的左边界不确定性较高,分别为 0.676 和 0.758。




Fig. 8 Loss function convergence curve

图 8 损失函数收敛曲线



Fig. 9 Examples of localization uncertainty

图 9 定位不确定性示例

为了进一步评估本文方法的推理性能,将其与 YOLOv11 和 Gaussian YOLOv11 在 CADc、BDD100K 及自建数据集上进行了可视化对比分析,结果如图 10 所示。从图

中可以观察到,由于不良天气的影响,目标物体的形态和轮廓边缘模糊不清,导致 YOLOv11 在检测结果中出现误检、漏检以及预测边界框与真实边界之间存在较大偏差的

问题。尽管 Gaussian YOLOv11 通过引入基于高斯分布的不确定性建模,在某些情况下比原始的 YOLOv11 表现得更好,但仍存在上述问题。相比之下,本文方法显著提升了 YOLOv11 在不良天气条件下的目标检测性能。这些改进不仅有效减少了因目标物体特征不明显而引起的漏检和误检,而且在目标物体的定位精度上也超越了 YOLOv11 和 Gaussian YOLOv11,这使得检测结果更接近真实标签。




Fig. 10 Visualization of detection results
图 10 检测结果可视化

表 6 展示了基线模型和本文方法分别在 CADC 验证集、BDD100K 验证集以及自建数据集验证集上的 TP 和 FP 数量。与 YOLOv11 相比,本文方法在 CADC、BDD100K 和自建数据集上的 TP 分别提升了 17.62%、4.10%、6.83%,同时,FP 值分别降低了 30.06%、22.48%、28.17%。TP 值的增加和 FP 值的减少表明本文方法有效改善了漏检、误检问题。

4 结语

不良天气会给目标检测算法带来额外的噪声和异常值,严重影响了算法检测的准确性。因此,本文提出了一种适用于不良天气环境下的不确定性建模和模型校准方

Table 6 Numerical evaluation of FP and TP				
表 6 FP 和 TP 的数值评估				
		YOLOv11	本文方法	变化率/%
CADC	TP	64 938	76 380	+17.62
	FP	39 365	27 530	30.06
	GT	106 854	106 854	0
BDD100K	TP	76 134	79 253	+4.10
	FP	40 876	31 689	-22.48
	GT	176 132	176 132	0
自建数据集	TP	13 641	14 573	+6.83
	FP	8 432	6 057	-28.17
	GT	25 127	25 127	0

法。通过使用拉普拉斯分布来建模预测边界框各方向的不确定性,与高斯分布相比,拉普拉斯分布能够更准确地捕捉不良天气下目标物体的位置变化,在 CADC 数据集上

的 mAP@0.5 提升了 1.7 个百分点,而信息熵的引入提高了分类的准确性,在 CADC 数据集上 mAP@0.5 提高了 0.8 个百分点。此外,本文对损失函数进行了重建,将量化的不确定性纳入模型训练过程,使得模型在训练时能够更加关注不确定性较高的预测,从而提高了模型的整体性能。本文方法在 CADC 数据集、BDD100K 数据集和自建数据集上的 mAP@0.5 分别较基线提高了 9.3、5.2 和 8.6 个百分点。同时,本文方法还显著降低了 FP 值,同时提高了 TP 值。实验结果表明,该方法提升了针对环境干扰的泛化性和鲁棒性,有助于提高自动驾驶感知算法的性能表现,降低自动驾驶的事故发生率。

虽然在实验室条件下取得了上述成果,但在将经过确认的目标检测算法用于实际预测活动时,仍面临一个关键挑战:由于缺乏应用环境下的试验数据,需要将不确定性从确认域插值到应用域。未来的工作将专注于探索和改进不确定性建模的方法,从而理解和量化目标检测算法在应用环境下的不确定性。

参考文献:

- [1] YIN H L, CHEN Z R, YAN J, et al. Review on uncertainty modeling in deep-learning-based environment perception of intelligent vehicles [C]// Shanghai: World General Artificial Intelligence Congress, 2022.
- [2] ZHANG X T, WANG J C, HE J T, et al. Motion planning under uncertainty for autonomous driving: opportunities and challenges [J]. Pattern Recognition and Artificial Intelligence, 2023, 36(1): 1-21.
张晓彤, 王嘉诚, 何景涛, 等. 面向不确定性环境的自动驾驶运动规划: 机遇与挑战 [J]. 模式识别与人工智能, 2023, 36(1): 1-21.
- [3] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]// IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [4] GIRSHICK R. Fast R-CNN [C]// IEEE International Conference on Computer Vision (ICCV), 2015: 1440-1448.
- [5] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [6] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector [C]// Computer Vision-ECCV, 2016: 21-37.
- [7] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection [C]// IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 779-788.
- [8] TAN M X, PANG R M, VAN L Q. EfficientDet: scalable and efficient object detection [C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 10781-10790.
- [9] GAL Y. Uncertainty in deep learning [D]. Cambridge: University of Cambridge, 2016.
- [10] LAKSHMINARAYANAN B, PRITZEL A, BLUNDELL C. Simple and scalable predictive uncertainty modeling using deep ensembles [C]// The 31st International Conference on Neural Information Processing Systems, 2017: 6405-6416.
- [11] FENG D, HARAKEH A, WASLANDER S, et al. A review and comparative study on probabilistic object detection in autonomous driving [J]. IEEE Trans on Intelligent Transportation Systems, 2022, 23(8): 9961-9980.
- [12] HE Y H, ZHU C C, WANG J R, et al. Bounding box regression with uncertainty for accurate object detection [C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019: 2883-2892.
- [13] CHOI J, CHUN D, KIM H, et al. Gaussian YOLOv3: an accurate and fast object detector using localization uncertainty for autonomous driving [C]// IEEE/CVF International Conference on Computer Vision, 2019: 502-511.
- [14] PENG L, WANG H, LI J. Uncertainty evaluation of object detection algorithms for autonomous vehicles [J]. Automotive Innovation, 2021, 4(3): 241-252.
- [15] FEN D, WANG Z N, ZHOU Y Y, et al. Labels are not perfect: inferring spatial uncertainty in object detection [J]. IEEE Trans on Intelligent Transportation Systems, 2022, 23(8): 9981-9994.
- [16] GASPERINI S, HAUG J, NIKOUEI MAHANI M A, et al. CertainNet: sampling-free uncertainty modeling for object detection [J]. IEEE Robotics and Automation Letters, 2022, 7(2): 698-705.
- [17] LEE Y, HWANG J W, KIM H I, et al. Localization uncertainty modeling for anchor-free object detection [C]// Computer Vision-ECCV 2022 Workshops, 2022: 27-42.
- [18] PITROPOV M, GARCIA D, REBELLO J, et al. Canadian adverse driving conditions dataset [J]. Robotics Research, 2020, 40(4-5): 681-690.
- [19] YU F, CHEN H F, WANG X, et al. Bdd100k: a diverse driving dataset for heterogeneous multitask learning [C]// IEEE Conference on Computer Vision and Pattern Recognition, 2020: 2633-2642.
- [20] YU W P, YANG T J N, CHEN C. Towards resolving the challenge of long-tail distribution in UAV images for object detection [C]// IEEE Winter Conference on Applications of Computer Vision (WACV), 2021: 3257-3266.
- [21] CHEN Y M, ZHANG J W, GU Y F. A novel detection method based on DETR for drone aerial images [C]// The 6th International Conference on Automation, Electronics and Electrical Engineering (AUTEEE), 2023: 784-788.

(责任编辑:陈维捷)