·智能汽车全栈环境感知技术专题·

基于YOLOv10的汽车路面不平特征识别方法研究*

王维强　贺章涛　周鹏　何一鸣　鲍洪文

（1.武汉科技大学汽车与交通工程学院，武汉 430081；2.博世华域转向系统（武汉）有限公司，武汉 430200）

【摘要】针对现有路面不平特征识别类型单一、对远小目标及低照度场景适应性差等问题，提出一种基于改进YOLOv10的检测算法。利用焦点调制网络替换快速空间金字塔池化（SPPF）模块，提升小目标检测精度；引入CPA-Enhancer架构增强低照度环境检测效果；采用形状交并比损失函数优化定位精度。经自建数据集试验结果表明：改进模型的mAP@0.5较原模型提升3.08%，通过实车部署验证其有效性，可实现减速带、凹坑、振动标线等7类路面不平特征的实时检测。

主题词：路面识别　YOLOv10　Focal Modulation网络　CPA-Enhancer网络　Shape-IoU损失函数

中图分类号：P391.4　　**文献标志码：**A　　**DOI:** 10.19620/j.cnki.1000-3703.20250418

Research on Road Surface Irregularity Recognition Method for Vehicles Based on YOLOv10

Wang Weiqiang, He Zhangtao, Zhou Peng, He Yiming, Bao Hongwen

（1. School of Automotive and Transportation Engineering, Wuhan University of Science and Technology, Wuhan 430081;
2. Bosch Huayu Steering System (Wuhan) Co., Ltd., Wuhan 430200）

【Abstract】To address the issues of single-type detection and poor adaptability in detecting distant small targets and low-light scenes for road surface irregularity recognition, this paper proposes an improved YOLOv10-based detection algorithm. The SPPF module is replaced with a Focal Modulation network to enhance small-target detection accuracy. The CPA-Enhancer is introduced to improve detection performance under low-light conditions. The Shape-IoU loss function is adopted to optimize localization precision. Experimental results on a self-built dataset demonstrate that the improved model achieves a 3.08% higher mAP@0.5 than the original model. Real-vehicle deployment further verifies the effectiveness of the proposed model, demonstrating its capability for real-time detection of 7 types of road surface irregularities, including speed bumps, potholes, and vibrating markings.

Key words: Road surface detection, YOLOv10, Focal Modulation network, CPA-Enhancer network, Shape-IoU loss function

【引用格式】王维强, 贺章涛, 周鹏, 等. 基于YOLOv10的汽车路面不平特征识别方法研究[J]. 汽车技术, 2026(5): 7-14.

WANG W Q, HE Z T, ZHOU P, et al. Research on Road Surface Irregularity Recognition Method for Vehicles Based on YOLOv10[J]. Automobile Technology, 2026(5): 7-14.

1　前言

车载视觉系统可提前识别路面减速带、凹坑、凸起等不平特征，为车辆控制提供先验信息，能够有效提升车辆行驶舒适性与安全性。因此，对于路面不平特征实时识别方法的研究具有重要的工程应用价值。

目前，主流目标检测模型可分为双阶段检测和单阶段检测[1]。其中，双阶段检测包括候选区域选取阶段和目标区域判断阶段，以基于区域的卷积神经网络（Region-based Convolutional Neural Network，R-CNN）、快速R-CNN等为代表。单阶段检测无需候选区域，以YOLO系列模型、单次多框检测算法为代表，因易实现精度与速率的平衡而广泛应用[2]。

在典型路面目标检测方面，胡均平等改进YOLOv3分别实现了路面坑洼、减速带和凹坑的检测[3-4]；邹俊逸等[5]通过实车验证了YOLOv7-tiny改进算法对减速带和凹坑的检测效果。但上述研究检测目标单一，未考虑对振动标线、横断沟槽、凸块等的检测，适用性受限。在路

*基金项目：国家自然科学基金青年科学基金项目（52202480）。

面小目标检测方面，王雪秋等[6]通过引入特征融合金字塔结构提升了对小目标的检测率；梁超等[7]在YOLOv8中新增1个检测头，提升了对远小车辆的检测精度；宣以国等[8]在YOLOv7中引入基于Wasserstein距离度量损失函数，提升了对路面小型裂缝的检测效果。但上述研究主要针对车辆和路面裂缝，对减速带、凹坑等远小目标的检测缺乏针对性，远距离时精度和召回率显著下降。在复杂场景检测方面，王子钰等[9]通过引入高效通道注意力机制和最小点距离交并比损失函数，提升了在尘雾环境下对车辆和行人的检测性能；王非凡等[10]融合自适应增强网络和特征增强网络，提升了夜间场景下的检测性能。但上述研究主要面向低照度环境下车辆、行人等路上目标，对路面不平特征的夜间检测仍缺乏针对性研究。

因此，本文提出一种基于改进YOLOv10的路面不平特征识别方法，利用焦点调制（Focal-Modulation）网络替换快速空间金字塔池化（Spatial Pyramid Pooling Fast，SPPF）模块，引入链式思考网络（Chain-of-Thought Prompted Adaptive Enhancer，CPA-Enhancer），采用形状交并比（Shape Intersection over Union，Shape IoU）边界框回归损失函数提升模型检测性能，并使用自建数据集进行离线训练，通过实车部署验证模型的有效性。

2　数据集采集处理

为保证训练数据的采集视角与实车部署时的检测视角一致，本文通过车载摄像头采集数据，构建数据集。采集路况包括城镇道路和乡村公路，覆盖晴天、阴天、雨天、夜晚4类场景，路面不平特征包括振动标线、井盖、凹坑、横向裂缝、减速带、横断沟槽和路面凸块7种类型。数据集共计3 109张图片，其分布如表1所示。使用Python库中Labelimg图像标注工具进行手动标注，如图1所示。

表1　数据集分布　　张

类型	晴天	雨天	阴天	暗光	总计
减速带	198	156	162	85	601
振动标线	178	149	186	76	589
凹坑	201	142	188	68	599
井盖	196	125	167	58	546
横向裂缝	137	96	97	69	399
横断沟槽	125	109	89	52	375
总计	1 035	777	889	408	3 109

为提升模型泛化能力，防止训练过拟合，对原始数据分布较少的图像进行数据增强，采用镜像、调整对比度，调整亮度、高斯滤波、自适应直方图均衡、随机偏移RGB通道6种方法进行随机增强，结果如图2所示。增强后的数据集共计9 301张图片，按照7∶2∶1划分数据集：训练集6 510张，测试集1 860张，验证集931张。



减速带　　凹坑　　振动标线和井盖



横向沟槽　　横断裂缝　　路面凸块

图1　数据标注



原始图像　　增强1　　增强2

（a）井盖



原始图像　　增强1　　增强2

（b）减速带



原始图像　　增强1　　增强2

（c）凹坑



原始图像　　增强1　　增强2

（d）振动标线



原始图像　　增强1　　增强2

（e）横向沟槽



原始图像　　增强1　　增强2

（f）横断裂缝



原始图像　　增强1　　增强2

（g）凸块

图2　数据增强结果

3　算法介绍

3.1　总体架构

YOLO系列算法的核心思想是将目标检测视为回归问题，通过神经网络得到输入图像中目标边界框的位置及其所属类别。YOLOv10[11]通过引入一种双重标签分配策略，避免对非极大值抑制（Non-Maximum Suppression，NMS）的依赖。在训练阶段，使用一对多检测头，提供更多的正样本；在推理阶段，通过梯度截断的方式，使用一对一检测头，无需NMS后处理。在效率提升方面，模型采用轻量级分类头、空间-通道分离下采样和基于秩的模块设计（C2fUIB），减少冗余计算。在精度方面，采用大核卷积和部分自注意力机制提升模型性能，适用于实时端到端目标检测。该版本模型弥补了以往版本在后处理和模型架构方面的不足，但在特定目标检测任务中仍存在以下问题：

a. SPPF模块可快速处理不同尺寸的输入图像，但对于远距离成像的远小目标（车辆前方80 m外的目标或像素尺寸小于32×32的目标）和复杂背景中目标的定位精度较差。

b. 网络架构对未退化条件下图像的自适应能力较弱，针对雾天、雨天及暗光低照度路况下的目标特征提取和检测分类准确度较低，检测精度有待提高。

c. 使用完整交并比（Complete Intersection over Union，CIoU）作为位置损失函数，当预测框和原始框的长宽比相同时，长宽比的惩罚项恒为0，且未考虑难易样本间的平衡问题。

为解决上述问题，本文提出改进架构如图3所示。该架构包括骨干网络（Backbone）、颈部（Neck-PAN）和检测头（Head）3个部分。其中，Backbone负责提取输入图像中的有效信息，Neck-PAN聚集并细化不同尺度的特征，Head对提供特征进行预测。利用Focal-

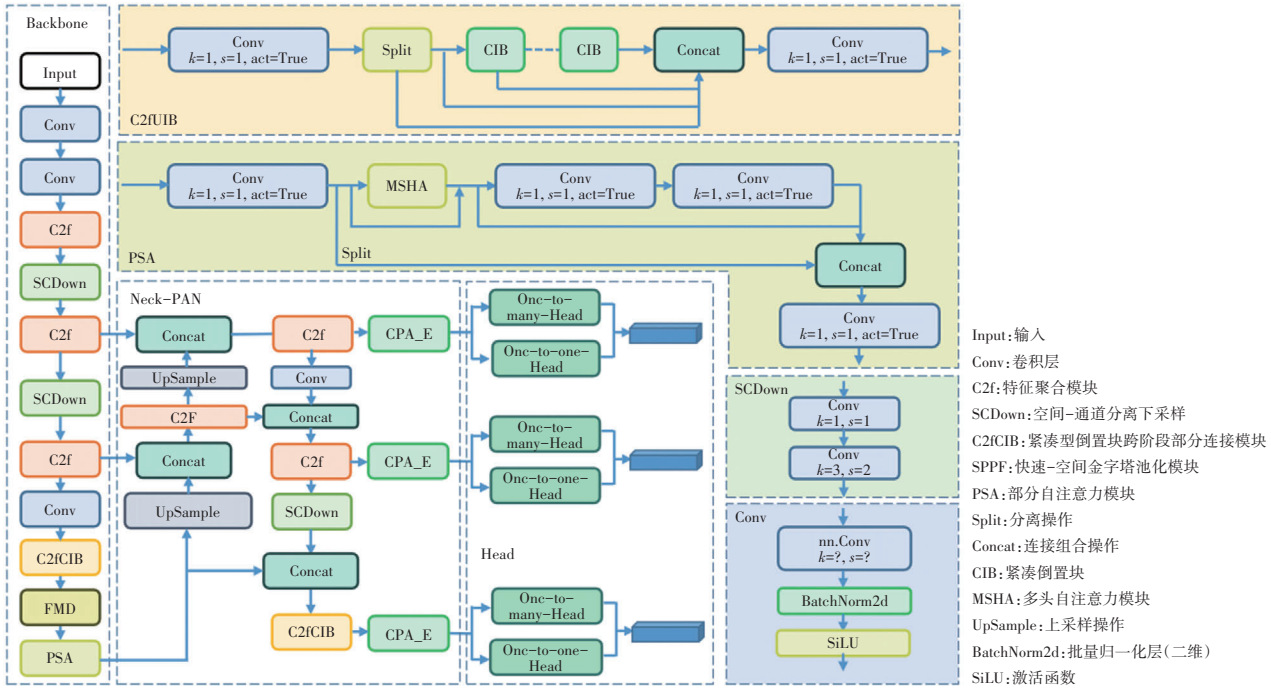


图3　总体网络架构

Modulation焦点调制网络替换原SPPF模块，提升模型对远小目标检测精度；引入CPA-Enhancer链式思考网络，提高低照度路况下目标识别检测能力；将Shape-IoU作为边界框回归损失函数，使边界框回归更精确。

3.2 焦点调制网络

焦点调制网络[12]的整体架构与Swin[13]、Focal Transformer[14]的结构基本相同，其核心创新在于采用焦点调制（Focal Modulation，FM）模块替换自注意力（Self-Attention，SA）模块，捕捉图像中的长距离依赖和上下文信息。该模块主要通过焦点上下文化、门控聚合和逐元素仿射变换实现。

输入视觉特征图 $X \in \mathbf{R}^{H \times W \times C}$，使用深度卷积层堆叠编码过程，通过与特征图的周围环境交互 T 和上下文聚合 M，令视觉特征 $x_i \in \mathbf{R}^C$ 生成特征表示：

$$y_i = q(x_i) \odot h\left(\sum_{l=1}^{L+1} g_i^l \cdot z_i^l\right), \quad y_i \in \mathbf{R}^C \tag{1}$$

式中：$q()$、$h()$分别为查询投影和线性投影函数，$\odot$ 为逐元素乘法，L 为深度卷积堆栈获得的上下文分层表示，g_i^l、z_i^l分别为 l 层级在位置 i 处的门控值和视觉特征。

焦点调制网络结构如图4所示，输入通过轻量级线性层后，在层级化的上下文语义模块和门控机制选择性聚合信息，经调制器与查询投影函数 q 进行交互处理后输出结果。

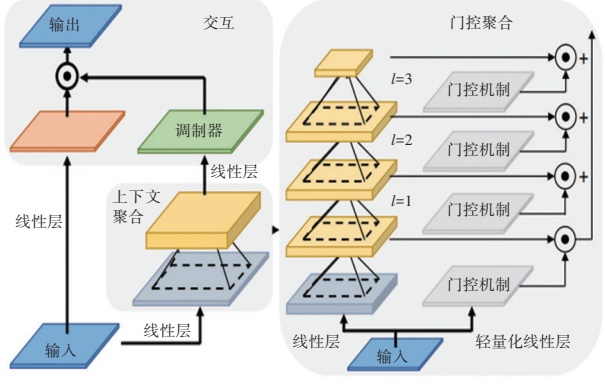


图4 焦点调制网络结构

3.3 CPA-Enhancer链式思考网络

CPA-Enhancer[15]通过引入链式思考（Chain-of-Thought，CoT）提示机制，增强对未知退化条件下图像的自适应能力，其结构如图5所示。该方法能够利用CoT提示对图像退化进行动态分析和适应，从而显著提升目标特征检测性能。则解码器第 i 层中生成的提示特征为：

$$\begin{cases} P_i = Hardswish(conv_{\mathrm{T},k\times k}(P_{i+1})), & i \in \{1,2\} \\ P_i \in \mathbf{R}^{2^{(3-i)}\hat{H} \times 2^{(3-i)}\hat{W} \times \frac{\hat{C}}{2^{(3-i)}}} \end{cases} \tag{2}$$

式中：$conv_{\mathrm{T},k\times k}$ 为 $k \times k$ 转置卷积，$Hardswish()$ 为激活函数。

第 i 层解码器中，第 j 个转换器模块的输出特征为：

$$\begin{cases} F_g^i = (F_g^{i,1},\cdots,F_g^{i,j},\cdots,F_g^{i,n}), & j \in \{1,2,\cdots,n\} \\ F_g^{i,j} = conv_{\mathrm{PC}}(X_1 \odot X_2) + F_m^{i,j} \end{cases} \tag{3}$$

式中：$conv_{\mathrm{PC}}$ 为逐点卷积，X_1、X_2 为经两条并行支路处理后的特征，$F_m^{i,j}$ 为残差连接的输入特征，n 为转换器模块数量。

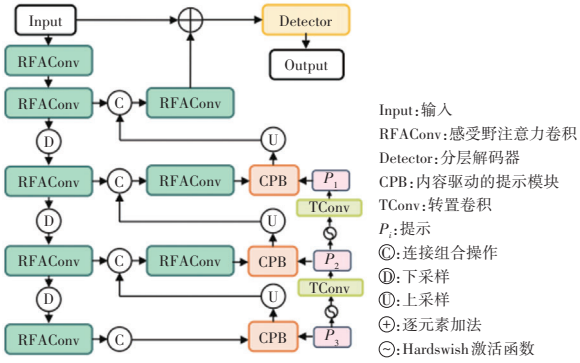


图5 CPA-Enhancer链式思考网络

3.4 Shape-IoU损失函数

YOLOv10以CIoU[16]作为边界框回归损失函数。实际应用中，当预瞄框 B 与实际框 B_{gt} 的长、宽比一致时，形状损失无法有效表达；小目标检测时，易导致 B 与 B_{gt} 长宽比相似度的梯度发散。Shape-IoU[17]损失函数通过关注边界框的形状和尺度计算损失，使边界框回归更加准确：

$$\begin{cases} L_{\mathrm{Shape-IoU}} = 1 - I + d^{\mathrm{sp}} + 0.5 \times \Omega^{\mathrm{sp}} \\ d^{\mathrm{sp}} = a_{\mathrm{h}} \dfrac{(x_{\mathrm{c}} - x_{\mathrm{c}}^{\mathrm{gt}})^2}{c^2} + a_{\mathrm{w}} \dfrac{(y_{\mathrm{c}} - y_{\mathrm{c}}^{\mathrm{gt}})^2}{c^2} \\ a_{\mathrm{w}} = \dfrac{2 \times (w^{\mathrm{gt}})^{\alpha}}{(w^{\mathrm{gt}})^{\alpha} + (h^{\mathrm{gt}})^{\alpha}} \\ a_{\mathrm{h}} = \dfrac{2 \times (h^{\mathrm{gt}})^{\alpha}}{(w^{\mathrm{gt}})^{\alpha} + (h^{\mathrm{gt}})^{\alpha}} \\ \Omega^{\mathrm{sp}} = \sum_{t=w,h} (1 - \mathrm{e}^{-\omega_t})^{\theta}, \theta = 4 \end{cases} \tag{4}$$

式中：I 为预瞄框与实际框的交并比[18]，d^{sp} 为形状加权距离项，Ω^{sp} 为现状差异项，a_{w}、a_{h} 为形状权重系数，c 为包含预瞄框和实际框的最小外接矩形的对角线长度，$(x_{\mathrm{c}},y_{\mathrm{c}})$、$(x_{\mathrm{c}}^{\mathrm{gt}},y_{\mathrm{c}}^{\mathrm{gt}})$ 分别为预瞄框和实际框的中心坐标，α 为比例因子，w^{gt}、h^{gt} 分别为实际框的宽和高，ω_{w}、ω_{h} 分别为宽度和高度方向差异系数，θ 为控制惩罚强度超参数。

根据文献[19]，针对小目标检测时的点距离距离为：

$$\begin{cases} D_{\mathrm{Dot}} = \mathrm{e}^{-\frac{D}{S}} \\ D = \sqrt{(x_{\mathrm{c}} - x_{\mathrm{c}}^{\mathrm{gt}})^2 + (y_{\mathrm{c}} - y_{\mathrm{c}}^{\mathrm{gt}})^2} \\ S = \sqrt{\dfrac{\sum_{i=1}^{M}\sum_{j=1}^{N_i} w_{ij} \cdot h_{ij}}{\sum_{i=1}^{M} N_i}} \end{cases} \tag{5}$$

式中：D为预瞄框与实际框中心点间的欧几里德距离，S为数据集中所有标注目标的平均尺寸，M为图像数量，N_i为图像中标注框的数量，w_{ij}、h_{ij}分别为第i张图像中第j个标注框的宽度和高度。

4 试验验证

4.1 离线试验

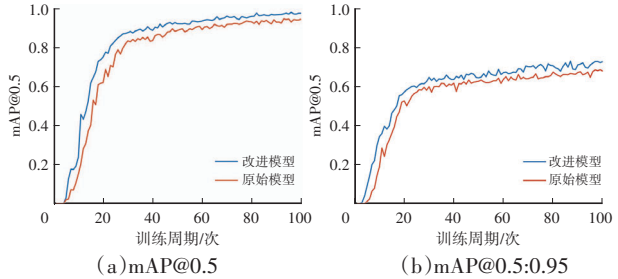
在目标检测任务中，精确率（Precision）P和召回率（Recall）R分别表示正确检出目标占所有检出目标和真实目标的比例，平均精度（mean Average Precision，mAP）综合反映模型的准确率。mAP@0.5、mAP@0.5∶0.95分别表示预测框与真实框的交并比阈值为0.5和0.5~0.95（步长0.05）时的平均精度。各指标计算式为：

$$\begin{cases} A_{\mathrm{mAP}} = \dfrac{1}{N}\displaystyle\sum_{i=1}^{N} A_{\mathrm{AP},i} \\ A_{\mathrm{AP},i} = \dfrac{1}{\sum_{k}^{n_k}(n_k - n_{k-1})}\{P_i(k)\cdot[P_i(k) - R_i(k-1)]\} \\ P = \dfrac{TP}{TP + FP} \\ R = \dfrac{TP}{TP + FN} \end{cases} \tag{6}$$

式中：N为目标类别数量，TP为正确检出的正样本，FP为误检的负样本，FN为漏检的正样本，$A_{\mathrm{AP},i}$为第i类目标P、R值的调和平均值，$P_i(k)$、$R_i(k)$分别为第i类目标在第k个阈值下的P、R值。

模型训练及验证的硬件环境为：中央处理器采用Intel Core i9-13900K，图像处理器使用英伟达RTX 4090，显存为24 GB；软件环境为Windows 10操作系统，在PyTorch 2.0.1框架下，使用Python语言。

模型试验结果如图6所示，改进模型与原模型的mAP@0.5结果分别为0.970、0.941，mAP@0.5:0.95分别为0.731、0.682。Focal Modulation增强了远小目标特征提取能力，加速了曲线早期收敛，同时，CPA-Enhancer提升了低照度样本的鲁棒性，减少了困难样本对训练的干扰，因而改进模型的稳定性较好。



（a）mAP@0.5　　（b）mAP@0.5:0.95

图6　模型训练mAP结果

4.2 消融试验

为验证本文模型中各改进模块的有效性，以YOLOv10n为基线模型进行消融试验，结果如表2所示。

表2　消融试验

FM	CPA	SIoU	P/%	R/%	mAP@0.5/%	参数/×10^{6}个	时间/s
			88.6	80.3	94.1	2.762	8.6
√			90.2	82.3	94.8	2.783	8.5
	√		87.6	84.5	95.6	2.961	8.9
		√	90.5	84.8	95.8	2.747	8.7
√	√		90.9	85.4	96.1	2.982	9.0
√	√	√	93.3	87.2	97.0	2.967	9.2

由表2可知，相较于基线模型，引入FM后，mAP@0.5提升0.7百分点，精确率和召回率分别提升1.6百分点、2.0百分点，说明焦点调制机制增强了模型对远小目标的特征提取能力，缩短了模型推理时间。引入CPA模块后，模型的召回率提升4.2百分点，mAP@0.5提升1.5百分点，精确率下降1.0百分点。虽然引入少量误检，但该模块增强了低照度退化场景下的特征鲁棒性，提升了模型对困难样本检测能力。引入形状损失函数后，mAP@0.5提升1.7个百分点，精确率和召回率分别提升1.9百分点、4.5百分点，且参数量不增反降，表明通过显式引入边界框形状与尺度信息，能够优化边界框定位精度。

因此，本文模型性能达到最优，mAP@0.5较基线提升2.9百分点，精确率和召回率分别达93.3%、87.2%。参数量和推理时间较基线略有增加，但检测性能显著提升，验证了本文方法的有效性。

4.3 对比试验

通过单个不平整特征目标的检测任务，对比分析本文模型与基线模型性能，结果如图7所示。本文模型对所有类别的检测置信度均高于原模型，其中对横断沟槽的提升最为显著。通过焦点调制机制，增强了对目标边缘与纹理细节的特征响应，使模型在常规场景下能够获得更清晰的边界表征，从而提升分类置信度。CPA-Enhancer模块引入的链式思考机制，在常规场景下有助于抑制背景噪声干扰，对目标的判别更加稳健。Shape-IoU损失函数通过更精准的边界框回归，减少预测框与真实框之间的偏移，间接提升了分类分支的置信度。



改进前　　改进后

（a）减速带



改进前　　改进后

(b)井盖



改进前　　改进后

(c)振动标线



改进前　　改进后

(d)横向裂缝



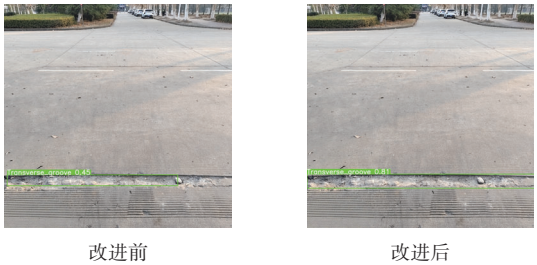
改进前　　改进后

(e)凹坑



改进前　　改进后

(f)路面凸块

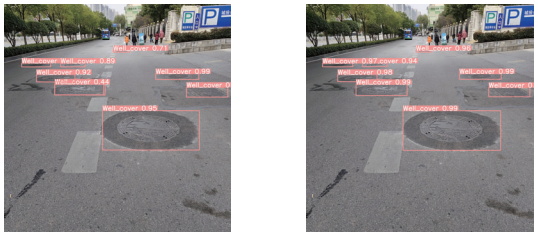


改进前　　改进后

(g)横断沟槽

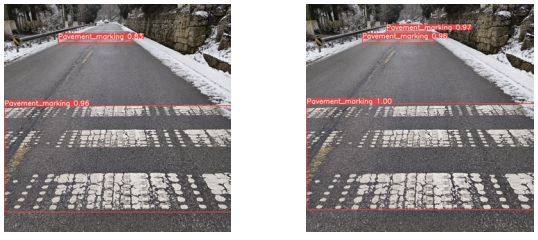
图7　单个目标检测对比结果

为了进一步分析本文模型的性能，针对连续目标、远小目标、路面积水和暗光照度等复杂环境条件的检测效果进行对比试验，结果如图8所示。



改进前　　改进后

(a)连续目标



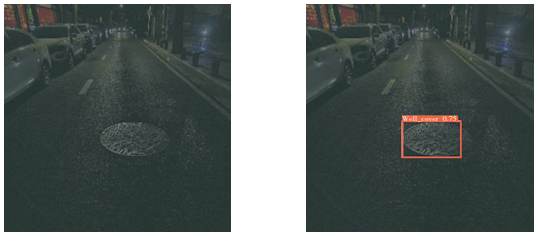
改进前　　改进后

(b)远小目标



改进前　　改进后

(c)路面积水



改进前　　改进后

(d)暗光低照度

图8　复杂条件下检测对比结果

由图8可知，在图8a中，基线模型与本文模型均可有效检出连续井盖目标，但本文模型的置信度显著高于基线模型。该现象主要源于FM模块增强了目标间的边缘区分能力，减少了连续目标间的特征混淆。在图8b的山区积雪路面，基线模型对远距离振动标线出现漏检，说明SPPF模块对远小目标的特征响应不足。本文模型能够通过层级化上下文语义聚合，增强模型对远小目标的特征表达。

在图8c中，两个模型均可正确检出雨天积水的连续凹坑路面，但CPA-Enhancer的链式思考机制可增强

模型自适应能力，优化特征提取的鲁棒性。在图8d中，暗光极低照度情况下的图像分辨率低、目标特征微弱，原模型的检测结果目标置信度低、漏检严重，本文模型对低照度图像进行自适应增强，结合Shape-IoU优化边界框定位，漏检现象明显减少，模型置信度显著提升。

4.4 实车试验

通过实车部署模型，验证本文方法实时检测效果。试验中，系统图像处理主控芯片为英伟达Orin-X，摄像头为索尼IMX490，可变速率的控制器局域网总线CAN-FD控制器为NXP TJA1153，本文模型以DSP+NPU格式导出。搭建路面不平特征实时检测系统，行车环境实时检测结果如图9所示。本文模型部署后能准确检出车辆前方的路面不平特征，该模型具有一定实用性。



(a)井盖检测



(b)振动标线检测

图9 路面不平检测系统

5 结束语

本文提出一种基于改进YOLOv10的路面不平特征检测模型，在参数量增加有限的条件下，显著提升了对减速带、凹坑、振动标线等7类目标的检测精度，在远小目标、低照度等复杂场景下性能改善明显。经自建数据集离线测试与实车部署验证，均证明了模型的有效性与实时检测能力。未来，将进一步扩充多天气、多光照条件下的数据集，并探索模型轻量化及嵌入式平台优化方案。同时，结合相机标定算法对路面不平特征的物理尺寸和距离进行精确测算，推动视觉感知信息在车辆智能决策中的深度融合与应用。

参 考 文 献

[1] TIAN Z, SHEN C H, CHEN H, et a1. FCOS: Fully Convolutional One-Stage Object Detection[C]// 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, Korea (South), 2020: 9626-9635.

[2] 王琳毅, 白静, 李文静, 等. YOLO系列目标检测算法研究进展[J]. 计算机工程与应用, 2023, 59(14): 15-29.
WANG L Y, BAI J, LI W J, et al. Research Progress of YOLO Series Target Detection Algorithms[J]. Computer Engineering and Applications, 2023, 59(14): 15-29.

[3] 胡均平, 黄强, 张洪伟, 等. 基于改进YOLOv3模型的车辆前方路面坑洼检测[J]. 传感器与微系统, 2022, 41(12): 130-133+138.
HU J P, HUANG Q, ZHANG H W, et al. Detection of Potholes in Road ahead of Vehicles Based on Improved YOLOv3 Model[J]. Transducer and Microsystem Technologies, 2022, 41(12): 130-133+138.

[4] 顾士洲, 严天一. 基于改进YOLOv3的路面正负障碍物检测研究[J]. 青岛大学学报(工程技术版), 2022, 37(2): 41-46.
GU S Z, YAN T Y. Research on Detection of Positive and Negative Obstacles on Road Surface Based on Improved YOLOv3[J]. Journal of Qingdao University (Engineering & Technology Edition), 2022, 37(2): 41-46.

[5] 邹俊逸, 刘畅, 郭文彬, 等. 面向智能车辆的路面凹凸障碍物识别方法研究[J]. 中国机械工程, 2024, 35(6): 951-961.
ZOU J Y, LIU C, GUO W B, et al. Research on Road Uneven Obstacle Recognition Method for Intelligent Vehicles[J]. China Mechanical Engineering, 2024, 35(6): 951-961.

[6] 王雪秋, 高焕兵, 郝泽萌. 改进YOLOv8的道路缺陷检测算法[J]. 计算机工程与应用, 2024, 60(17): 179-190.
WANG X Q, GAO H B, JIA Z M. Improved Road Defect Detection Algorithm Based on YOLOv8[J]. Computer Engineering and Applications, 2024, 60(17): 179-190.

[7] 梁超, 来跃深, 常宏. 改进YOLOv8的道路小目标检测算法[J]. 西安工业大学学报, 2024, 44(4): 514-524.
LIANG C, LAI Y S, CHANG H. Small Road Object Detection Algorithm Based on Improved YOLOv8[J]. Journal of Xi'an Technological University, 2024, 44(4): 514-524.

[8] 宣以国, 余成波, 蒋启超, 等. 基于改进YOLOv7的道路裂缝和坑洞检测算法[J]. 科学技术与工程, 2024, 24(17): 7205-7213.
XUAN Y G, YU C B, JIANG Q C, et al. Improved YOLOv7 Road Crack and Pothole Detection Algorithm[J]. Science Technology and Engineering, 2024, 24(17): 7205-7213.

[9] 王子钰, 张建成, 刘元盛. 改进YOLOv8n的尘雾环境下目标检测算法[J]. 汽车技术, 2025(6): 1-7.
WANG Z Y, ZHANG J C, LIU Y S. Improved YOLOv8n Object Detection Algorithm in Dust and Fog Environment[J]. Automobile Technology, 2025(6): 1-7.

[10] 王非凡, 陈希爱, 任卫红, 等. 基于图像自适应增强的低照度目标检测算法[J]. 计算机工程, 2024, 50(10): 352-

361.
WANG F F, CHEN X A, REN W H, et al. Low-Illumination Object-Detection Algorithm Based on Image Adaptive Enhancement[J]. Computer Engineering, 2024, 50(10): 352-361.
[11] WANG A, CHEN H, LIU L H, et al. YOLOv10: Real-Time End-to-End Object Detection[EB/OL]. (2024-10-30) [2025-09-22]. https://arxiv.org/abs/2405.14458.
[12] YANG J W, LI C Y, DAI X Y, et al. Focal Modulation Networks[C]// Advances in Neural Information Processing Systems 35. New Orleans, LA, USA: NeurIPS, 2022.
[13] LIU Z, LIN Y T, CAO Y, et al. Swin Transformer: Hierarchical Vision Transformer Using Shifted Windows [EB/OL]. (2021-08-17) [2025-09-22]. https://arxiv. org/abs/2103.14030.
[14] YANG J W, LI C Y, ZHAGN P C, et al. Focal Self-Attention for Local-Global Interactions in Vision Transformers[C]// Advances in Neural Information Processing Systems 34. New Orleans, LA, USA: NeurIPS, 2021.
[15] ZHANG Y W, WU Y, LIU Y M, et al. CPA-Enhancer: Chain-of-Thought Prompted Adaptive Enhancer for Downstream Vision Tasks under Unknown Degradations[C]// ICASSP 2025-2025 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Hyderabad, India: IEEE, 2025.
[16] ZHENG Z H, WANG P, REN D W. Distance-IoU Loss: Faster and Better Learning for Bounding Box Regression [EB/OL]. (2019-11-19) [2025-09-22]. https://arxiv. org/abs/1911.08287.
[17] ZHANG H, ZHANG S J. Shape-IoU: More Accurate Metric Considering Bounding Box Shape and Scale[EB/OL]. (2024-01-12) [2025-09-22]. https://arxiv. org/abs/2312.17663.
[18] YU J H, JIANG Y N. UnitBox: An Advanced Object Detection Network[C]// Proceedings of the 24th ACM international conference on Multimedia. New York, NY, United States: ACM: 516-520.
[19] XU C, WANG J W, YANG W, et al. Dot Distance for Tiny Object Detection in Aerial Images[C]// 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Nashville, TN, USA: IEEE, 2021: 1192-1201.

（责任编辑　瑞　秋）
修改稿收到日期为2025年9月22日。

《汽车工艺与材料》投稿须知

《汽车工艺与材料》于1986年创刊，是由中国第一汽车集团有限公司主办的国内外公开发行的汽车材料与制造技术类月刊，目前已入选《中文核心期刊要目总览》（第二版）、RCCSE中国准核心学术期刊（B+）、中国核心期刊（遴选）数据库、中国学术期刊综合评价数据库、欧洲学术出版中心数据库（EuroPub）、哥白尼精选期刊数据库（ICI Journals Master List）、EBSCO International数据库、J-Gate数据库。

《汽车工艺与材料》以“为中国报道汽车制造，为汽车引领工艺材料”为办刊宗旨，致力于报道以汽车轻量化技术和智能制造技术为核心的先进制造技术与材料应用技术，重点关注电动汽车蓄电池、电机、电控关键材料技术，燃料电池材料技术，高强度钢、铝镁合金、非金属材料及其成形技术，连接技术，智能装备与绿色制造等，以期通过高质量学术内容的出版和传播助推行业创新技术的交流与发展。

《汽车工艺与材料》杂志关注领先的整车及零部件企业和材料、装备等供应商，及时报道汽车行业最新的产品设计、制造、材料、加工技术、生产装备、检测技术等方面的成功案例。

主要栏目：

AT&M视界、生产现场、材料应用、生产装备、检测技术、数字化园地、行业动态等。

投稿要求：

（1）来稿须具有独创性并与实践相结合，文章字数最好控制在5 000～8 000字。

（2）来稿不能在国内、外公开杂志上发表过，请勿一稿多投。

（3）来稿的试验方法、试验数据、试验结论必须准确、可靠。

（4）来稿须包括以下项目：题名、作者姓名、作者单位、摘要（200字左右）、参考文献等。来稿采用word文档的格式。

（5）来稿文章格式应符合一般科技论文格式，或参考近期本刊所刊登文章格式。

（6）文章必须附有公开发表的、体现本领域最新研究成果的参考文献，且在文中应标注文献引用处。

（7）本刊使用网站投稿，投稿网址：http://qcgyycl.cbpt.cnki.net，咨询电话：0431-82026054。

竭诚欢迎汽车行业及相关各界的专家学者积极向本刊投稿。