

基于改进 YOLOv11 的家用燃气表读数自动检测方法

王 硕¹ 蒋力畅¹ 沈栩同¹ 孙 敏^{1*}

WANG Shuo JIANG Lichang SHEN Xutong SUN Min

摘 要

为解决传统燃气表检测和读数效率低、精度差的问题,文章提出了一种基于改进 YOLOv11 的家用燃气表读数自动检测方法。该方法通过引入混合局部通道注意力机制(mixed local channel attention, MLCA)增强模型对重要信息的关注度,采用多分支卷积(inception depthwise convolution, IDC)提升模型的多尺度特征提取能力并降低计算复杂度,并基于自适应阈值焦点损失(adaptive threshold focal loss, ATFL)改进损失函数以提高模型在类别不平衡情况下的整体性能。从实验结果可知,经过改进后得到的模型准确率、召回率、平均精度等各项指标均比基准模型提高 2%、1.5%、4.7%,推理速度比基准模型快 18.51 帧/s。该方法在实际应用中准确度高、速度快,具有较好的应用前景。

关键词

YOLOv11; 目标检测; 燃气表读数; 注意力机制

doi: 10.3969/j.issn.1672-9528.2026.03.018

0 引言

准确、稳定的燃气表计量结果对保证公平、高效地使用能源来说十分重要。传统的机械式膜式燃气表用机械滚轮进行气量计量记录,无法将数据导出,主要依靠人工观察数据、记录、分析、判断,主观性强、效率低、识别率低。现有的数显仪表识别方法在不同的应用场合下存在着各自的优缺点。

传统的模板匹配^[1]、特征提取^[2]等方法均依靠人工制定规则实现,对于环境的变化以及复杂的背景来说,适应性较差,识别精度和鲁棒性不高。以深度学习为代表的算法由于具有很强的特征提取能力,以及对复杂场景的适应性,被广泛使用。朱立倩^[3]提出了一种基于深度学习的数显仪表字符识别方法,由字符区域定位网络和字符识别网络组成。字符区域定位网络是改进的 Faster R-CNN,用 ResNeXt-101 替换原来的骨干网络,从而提高分类和定位的准确性。字符识别网络是用卷积神经网络及带有注意力机制的长短时记忆网络,提高字符识别准确率。但是该方法在计算复杂度以及模型体积上还有改进空间,模型参数量大,造成模型运行时内存占用多。

另一种轻量级的目标检测方法则是基于 YOLOv7 的数显仪表检测和读数方法^[4]。该方法通过改变参数的数量、计算量以及处理的密度来提高性能,在实时的应用中也具有较好

的性能和效率。但还存在着一定的优化空间,特别是检测精度上。

寇文博^[5]提出用 YOLOv5s+Transformer 来识别数显仪表的算法。该方法先用 STN 空间变换网络将倾斜或者旋转的图像调整成水平、垂直方向一致的图像。接着,编码器网络对矫正后的字符图像进行特征编码,编码器采用参数量更少、计算复杂度更低的 Swin Transformer 模型的设计。最后用 Transformer 解码器对编码的内容进行解码,得到对应字符的预测序列。该方法在字符识别精度、识别速度上表现较好,但是模型参数量仍然很大。

本文提出了一种基于改进 YOLOv11 的家用燃气表读数识别方法,以达到高效、准确地对仪表进行检测和读数的目的。

1 YOLOv11

YOLOv11^[6]是 Ultralytics 公司于 2024 年推出的全新 YOLO 系列目标检测模型,保持了 YOLO 系列单次推理的优势,并且在速度、精度、功能多样化等方面都得到了明显提升。网络架构优化部分,YOLOv11 采用 C3k2 的方式改进了卷积模块的设计,利用浅层特征快速提取、深层特征高效融合的特点,在保持精度的基础上提高网络结构的效率。C2PSA 机制在 C2 模块中加入金字塔空间注意力(PSA),加强对于繁杂情形的语义理解水平。YOLOv11 用深度可分离卷积(DWConv)^[7]来检测头部,用轻量化的 DWConv 代替原来的检测头部,减小了计算量的同时保证了精度。EIoU 损失函数^[8]是 IoU 损失函数的扩展,把边界框的重叠面积、长宽比、

1. 苏州城市学院 江苏苏州 215104

[基金项目] 江苏省高等学校大学生创新创业训练项目计划“家用燃气表读数自动读取系统设计”(202413983101Y)

中心点偏移等都考虑进去,从而提高检测精度。YOLOv11 使用混合精度训练的方式,利用 FP16 技术^[9]来加速训练速度和减少现存使用量,进而提升训练效率。其网络结构图如图 1 所示。




图 1 YOLOv11 网络结构

虽然 YOLOv11 在很多基准测试中表现较好,但因使用了更加复杂的网络结构以及算法改进,使得训练和推理过程中计算复杂度增大,需要更高的硬件要求、更多的内存和计算资源才能达到最好的性能,对资源受限的环境来说是个难题。

2 改进的 YOLOv11 算法结构

为提高复杂环境下燃气表检测读数的精度和效率,在原始 YOLOv11 基础上进行如下改进:加入混合局部通道注意力机制,加强模型对重要信息的关注程度;加入多分支卷积,提升模型多尺度特征提取能力;采用自适应阈值焦点损失函数,改善模型在类别不平衡情况下的总体表现。

2.1 引入混合局部通道注意力机制 (MLCA)

混合局部通道注意力机制 (mixed local channel attention, MLCA) 是轻量级的注意力机制^[10],将局部和全局特征信息、通道特征信息和空间特征信息结合起来,从而提高网络对目标有用特征的识别能力。

图 2 展示了 MLCA 注意力机制的流程。其具体操作为:对于局部空间注意力分支,将输入特征图划分为多个非重叠的局部窗口,对每个窗口内计算像素级注意力权重,通过 1×1 卷积生成注意力图 $M \in \mathbb{R}^{H \times W}$,然后使用 Sigmoid 函数激活,将其归一化到 $[0,1]$,接着进行局部特征增强,将权重图

M 与原始特征逐点相乘:

$$X_{\text{local}} = X \otimes M \quad (1)$$

对于通道注意力分支,对每个通道进行全局平均池化,得到通道描述向量 $z \in \mathbb{R}^C$,然后通过两层全连接层 (ReLU 和 Sigmoid) 生成通道权重 $w \in \mathbb{R}^C$:

$$w = \sigma(W_2(\delta(W_1 z))) \quad (2)$$

式中: W_1 和 W_2 为全连接层权重; δ 为 ReLU; 接着进行通道特征增强,将权重 w 与原始特征逐通道相乘:

$$X_{\text{channel}} = X \otimes w \quad (3)$$




图 2 MLCA 注意力机制的流程

最后将两个分支的输出相加进行特征融合:

$$Y = X + X_{\text{local}} + X_{\text{channel}} \quad (4)$$

将 YOLOv11 骨干网络层的 C2PSA 模块中的注意力层替换成 MLCA,组合成 C2PSA-MLCA 模块,在不增加模型计算复杂度的情况下,利用 MLCA 结合局部和全局特征的能力,加强模型对重要信息的关注,提升模型对特征表示的性能以及适应性。

2.2 引入多分支卷积 (IDC)

燃气表表盘目标由于拍摄角度或者环境干扰等原因会产生多尺度特征,从而影响模型的检测能力。大核卷积虽然能增大感受野,但是高计算成本会降低模型推理速度。为了克服以上问题,本文提出用多分支卷积 IDC (inception depthwise convolution)^[11]将大核卷积分成多个并行分支,分别对局部和全局特征进行处理,在保证大感受野的同时大大降低了模型的总计算复杂度,提高了模型的推理速度,实现了高效的轻量化。图 3 为多分支卷积的示意图,其具体步骤为:

小核卷积:第一个分支用 3×3 小核卷积来处理局部特征。

该卷积操作的计算成本虽然不高，但可以保留细节信息。

水平带状卷积：第二个分支用 1×11 卷积核，在宽度方向上做卷积，可以有效地捕捉宽度方向上的全局信息。

垂直带状卷积：第三个分支用 11×1 的卷积核，在高度方向上只做卷积，可以捕捉到高度方向的全局依赖。




图3 多分支卷积的示意图

第四个分支采用恒等映射，保持输入通道中部分特征不变，即直接用恒等映射（Identity Mapping）来减少不必要的计算。这样可以使得部分通道不需要经过卷积操作，从而提高计算效率。

Concat 即将四个分支的特征通道维度拼接在一起，得到最后输出特征。由于每一个分支都捕捉到了不同的特征（局部、全局、高度、宽度），IDC 可以保持大感受野的同时减小计算量。

YOLOv11 的特征提取模块将 IDC 替换到骨干网络层中，用作 C3k2 模块以替换传统的卷积操作，从而在不增加计算量的情况下得到更大的感受野，提高 Backbone 的多尺度特征提取能力。在每一个 Head 的输出层之后加上 IDC 来增强 neck 层的多尺度特征。

2.3 基于自适应阈值焦点损失（ATFL）

ATFL（adaptive threshold focal loss）^[12] 在 Focal Loss 的基础上加入了动态调节的阈值，将阈值解耦与针对性相结合，自适应地调节损失权重以适应不同的样本特征，从而提高了模型对目标的识别能力。采用焦点机制之后，ATFL 对于容易被分类的样本以及不容易被分类的样本的权重都发生了改变，使得模型受容易被分类的样本的影响变小，受难分类的样本的影响变大，在类别不平衡的情况下提高了模型的整体性能。

其实现方式为根据当前批次或历史统计信息（如预测概率的均值、分位数）动态调整阈值 T_i ，然后调整因子与阈值的结合，当 $|p_i - T_i| \geq \delta$ 时，视为易分类样本，降低其损失权重；当 $|p_i - T_i| < \delta$ 时，视为难分类样本，保留更高的损失权重。其中 p_i 为模型对真实类别的预测概率， δ 为容忍区间。该损失函数形式为：

$$\text{ATFL}(p_i) = -\alpha_i \left(1 - \frac{|p_i - T_i|}{T_i}\right)^\gamma \log(p_i) \quad (5)$$

式中： α_i 为类别平衡权重； γ 为控制难易样本的聚焦强度； $\left(1 - \frac{|p_i - T_i|}{T_i}\right)^\gamma$ 为调制因子，用于动态调整权重。当 p_i 接近 T_i 时（难样本）权重增大；当 p_i 远离 T_i 时（易样本）权重减小。阈值 T_i 随训练过程动态调整，通过辅助网络或可学习参数直接预测阈值 T_i ，使其与模型训练同步优化。

使用 ATFL 替换 YOLOv11 中传统的交叉熵损失进行训练，更加重视检测难样本，不会因为对易检测样本过于优化而导致过拟合的问题，从而提高整体检测准确率，ATFL 具有自适应性，可以自动调整损失函数，使它根据数据分布自行调节，进一步提高了模型的泛化性能，在不同的环境下都能够得到很好地应用。

3 实验设计与结果分析

3.1 数据集与实验设置

本实验使用的数据集是自采集数据集，有 3 668 张图片，图片平均大小为 $2\,100 \text{ px} \times 1\,400 \text{ px}$ ，按照 7:1:2 的比例分成训练集、测试集、验证集。试验的硬件环境 CPU 为 12th Gen Intel(R) Core(TM) i7-12700H，GPU 为 NVIDIA GeForce RTX 3060 Laptop；实验平台的软件环境为基于 Windows11 版本、Python-3.9.21，CUDA-12.6，PyTorch-2.2.2 搭建的深度学习框架。

训练参数：输入图像分辨率为 $640 \text{ px} \times 640 \text{ px}$ ，epochs 为 300，batch size 为 16，workers 为 8， lr_0 为 0.01， lr_t 为 0.01，momentum 为 0.937，权重衰减系数为 0.000 5，实验均在相同的环境中进行。

3.2 模型的评价指标

本文采用准确率（Precision, P ）、召回率（Recall, R ）、平均精度值（mAP）、推理速度作为该模型的主要评价指标。精确率就是正样本中被模型预测为正样本的比例，召回率就是预测为正的样本中确实为正样本的比例。AP 表示目标检测对于单个类别的准确率；mAP 表示平均 AP 值；mAP@50 表示 IoU（intersection over union）阈值为 50% 时的 mAP 值；mAP@50-95 表示 IoU 从 50% 开始，以步长为 0.05 上升到 95% 时的平均 mAP 值。各指标的计算公式为：

$$P = \frac{TP}{TP + FP} \quad (6)$$

$$R = \frac{TP}{TP + FN} \quad (7)$$

$$AP = \int_0^1 P(R) dR \quad (8)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i \quad (9)$$

式中: TP 是模型对正样本正确的识别个数; FP 是模型把负样本误判成正样本的个数; FN 是模型把正样本当作负样本识别出来的样本数; n 是标签种类。

3.3 消融实验

为了检验本文所提改进算法的有效性,用 YOLOv11 作为基准模型,以准确率 (Precision)、召回率 (Recall)、平均精度值 (mAP)、推理速度 (FPS) 等为检测指标,采用逐步改进各个模块的方法进行消融实验。实验统计结果如表 1 所示。

表 1 消融实验结果

Model	Module			P	R	mAP50	mAP50-95	FPS /(帧·s ⁻¹)
	A	B	C					
1				0.873	0.781	0.832	0.586	160.36
2	√			0.886	0.782	0.835	0.596	132.69
3		√		0.875	0.788	0.874	0.588	205.61
4			√	0.879	0.790	0.856	0.592	148.25
5	√	√	√	0.893	0.796	0.879	0.601	178.87

模块 A 为用 MLCA 替换 YOLOv11 骨干网络层的 C2PSA 模块中的注意力层;模块 B 为用多分支卷积 IDC 替换 C3k2 模块的卷积,在每个 Head 的输出层后面加上 IDC;模块 C 为用 ATFL 代替 YOLOv11 的交叉熵损失。从模型 1 和 2 的对比可知, P 、 R 、mAP50、mAP50-95 分别提高了 1.3%、0.1%、0.3%、1%,说明用 MLCA 替换 C2PSA 模块中的注意力层之后,模型在精确率以及特征提取精确定位方面得到了明显改善,虽然因为这个机制额外的卷积操作和矩阵运算使得模型的计算复杂度增加了 27.67 帧/s,但可以接受;从模型 1 和 3 的对比可知, P 、 R 、mAP50、mAP50-95 分别提高了 0.2%、0.7%、4.2%、0.2%,推理速度提高了 45.25 帧/s,说明引入多分支卷积 IDC 替换 C3k2 模块之后,模型检测目标的能力大大提高,多个并行分支卷积操作降低了计算量,极大地提高了模型的推理速度;从模型 1 和 4 的对比可知, P 、 R 、mAP50、mAP50-95 分别提高了 0.6%、

0.9%、2.4%、0.6%,说明模型能够更加细致地优化难样本和易样本的检测效果,减少 FP 和 FN 的数量。经过三方面算法改进之后,现模型 P 、 R 、mAP50、mAP50-95 分别提高 2%、1.5%、4.7%、1.5%,推理速度提高 18.51 帧/s,消融实验表明本文提出的每一个改进模块都会对基准模型产生一定的积极作用,综合改进之后,现模型各个性能指标都优于基准模型。

3.4 算法对比实验

为了进一步检验算法改进后是否有效、先进,在测试集上用本文算法与目标检测领域中常用的算法做检测性能比较,实验统计结果如表 2 所示。从实验结果可以看出,本文模型各个性能评价指标都优于 SSD^[13]、YOLOv3^[14]、Faster R-CNN^[15]、FPN^[16];与 YOLOv3-tiny、YOLOv8n 相比,本文模型虽然推理速度慢一些,但其他性能指标都好于前者;与 YOLOv8s、RT-DETR 相比, mAP50-95 稍低,说明本文模型在目标定位精度方面稍差,但是推理速度分别为 30.66 帧/s、100.64 帧/s,更适合高实时性需求的应用场景。根据各个性能评价指标,本文模型在目标检测任务上具有较好的准确性、高效率,可以很好地平衡检测精度和推理速度,在各种实际应用场合下都适用。

表 2 不同目标检测算法在测试集上的性能对比

Model	P	R	mAP50	mAP50-95	FPS /(帧·s ⁻¹)
SSD	0.821	0.718	0.722	0.593	92.27
YOLOv3	0.781	0.732	0.710	0.558	78.24
YOLOv3-tiny	0.682	0.606	0.581	0.515	182.43
Faster R-CNN	0.856	0.783	0.804	0.565	41.57
YOLOv8n	0.828	0.762	0.772	0.597	201.74
YOLOv8s	0.842	0.791	0.837	0.624	148.21
FPN	0.781	0.705	0.685	0.532	92.47
RT-DETR	0.881	0.810	0.854	0.652	78.23
Ours	0.893	0.796	0.879	0.601	178.87

3.5 检测结果可视化

图 4 和图 5 分别为基准模型和改进模型各性能指标随训练轮数的变化情况,可以看到本文改进后的模型具有明显的优势。




图 4 基准模型




图5 改进模型

为了验证本文模型在实际背景中的性能,选择了自采集测试集中具有代表性的燃气仪表图进行可视化实验,结果如图6所示。可以看到本文模型可以有效准确地识别燃气表并读数,且相较于基准模型效率更高。




图6 代表性的燃气仪表图的可视化实验

4 结语

准确、稳定的燃气表计量结果对保证公平、高效地使用能源有着十分重要的意义。但是现有的模型算法在对燃气表进行检测、读数时还存在部分不足,模型的检测精度和实时性较差。因此本文提出一种基于YOLOv11改进的目标检测算法,用MLCA混合局部通道注意力机制、多分支卷积IDC和基于ATFL的损失函数改进来提高自采集测试集上的消融实验和算法对比实验证明了模型改进的有效性与先进性。经过改进后的模型比基准模型 P 、 R 、 $mAP50$ 、 $mAP50-95$ 分别提高了2%、1.5%、4.7%、1.5%,推理速度提升了18.51帧/s,在保证高精度的基础上极大减少了计算复杂度,提高了模型的推理速度。

虽然本研究取得了一些成果,但在光照较暗、数字部分被遮等复杂背景中检测时,模型的检测精度会受到影响。因此,今后将对模型加入上下文信息模块来提高模型在复杂背景下的目标检测能力。另外用剪枝蒸馏法来优化模型,以达到提高模型实时检测的目的。

参考文献:

- [1] 邓清男,石晓龙.变电站室内数显仪表的读数识别[J].工业仪表与自动化装置,2018(2):86-89.
- [2] 陆靖滨,许丽.基于自适应特征提取的数显仪表识别系统[J].现代电子技术,2017,40(24):147-150.
- [3] 朱立倩.基于深度学习的数显仪表字符识别[J].计算机技术与发展,2020,30(6):141-144.
- [4] 章芮宁,闫坤,叶进.轻量化YOLO-v7的数显仪表检测及读数[J].计算机工程与应用,2024,60(8):192-201.
- [5] 寇文博.基于YOLOv5s和Transformer的数显仪表识别算法研究[D].西安:长安大学,2023.
- [6] KHANAM R, HUSSAIN M.YOLOv11: an overview of the key architectural enhancements[EB/OL].(2024-10-23)[2026-03-16].<https://doi.org/10.48550/arXiv.2410.17725>.
- [7] WOO S, PARK J, LEE J Y, et al.CBAM: convolutional block attention module[EB/OL].(2018-07-18)[2026-03-16].<https://doi.org/10.48550/arXiv.1807.06521>.
- [8] ZHANG Y F, REN W Q, ZHANG Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. Neurocomputing, 2022,506:146-157.
- [9] SANCHEZ-FLORES A, FORNT J, ALVAREZ L, et al. Energy and precision evaluation of a systolic array accelerator using a quantization approach for edge computing[J]. Electronics, 2024, 13(14): 2822.
- [10] FU Y A, ZHANG Y. Lightweight rice leaf disease detection method based on improved YOLOv8[J]. Engineering letters, 2025, 33(2): 402-417.
- [11] 张萌,李响,张经纬.基于图像偏移角和多分支卷积神经网络的旋转不变模型设计[J].电子与信息学报,2024,46(12):4522-4528.
- [12] 崔家礼,张林,郑瀚.基于MDA-YOLOv10的融合图像车辆行人检测方法[J/OL].红外技术,1-9[2026-03-16].<https://link.cnki.net/urlid/53.1053.TN.20250331.1749.004>.
- [13] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[C]//Computer Vision—ECCV 2016.Berlin: Springer, 2016: 21–37.
- [14] REDMON J, FARHADI A. YOLOv3: an incremental improvement[EB/OL].(2018-04-08)[2026-03-16].<https://doi.org/10.48550/arXiv.1804.02767>.

Transformer 多模态特征提取下图像目标边缘检测方法

刘庆霞¹ 司贺杰¹ 王俊方¹ 徐恕贞¹
LIU Qingxia SI Hejie WANG Junfang XU Shuzhen

摘 要

在对图像目标边缘检测时，复杂多变的光照条件会导致图像局部区域出现明暗不均、过曝或欠曝等现象。基于局部梯度或单一模态特征的方法由于缺乏对图像全局语义的理解，易受噪声影响，造成边缘模糊或断裂，导致检测精度较低。为解决这一问题，文章提出了一种基于 Transformer 多模态特征提取的图像目标边缘检测方法。首先，将采集的彩色图像通过灰度转换降低色彩干扰并采用高斯平滑抑制噪声，利用局部 Otsu 算法自适应计算最优分割阈值实现目标与背景的精确分离；其次，基于卷积神经网络（convolutional neural network, CNN）提取分割目标的多模态特征，结合 Transformer 的自注意力机制（Self-Attention）进行特征加权融合以增强对图像全局语义的理解，突出边缘特征，解决边缘模糊或断裂问题；最后，采用深度学习算法通过构建目标区域边缘概率图并优化损失函数实现边缘检测，再经掩码处理去除干扰得到最终边缘检测结果。实验结果表明，所提方法在实际应用中能够精准检测出目标区域的边缘，且边缘结构完整度数值为 0.945，检测精度较高。

关键词

Transformer；多模态特征；图像；边缘检测；目标边缘；特征增强；注意力机制

doi: 10.3969/j.issn.1672-9528.2026.03.019

0 引言

在复杂场景中，图像目标边缘检测能够精准提取物体的边缘轮廓，是图像分割、目标识别等多个领域的关键技术。在实际应用中，现有的检测方法会受到光照变化和纹理干扰的影响，且仅能捕捉图像的局部像素强度变化，缺乏对图像目标的语义理解，再通过局部梯度值识别边缘，导致方法的边缘检测精度不高。

在该研究背景下，针对目标检测领域，多位学者提出了多种图像目标边缘检测方法。张喜民等^[1]在双三次插值作用

下对目标图像进行映射，通过邻域选取、权重计算等合成插值，再利用 Zernike 矩在单位圆内展开图像，提取旋转不变特征，求解边缘参数、估计边缘方向、计算亚像素偏移值以实现边缘检测。然而，双三次插值主要基于局部邻域像素计算，在复杂光照下，局部区域明暗不均、过曝或欠曝会使邻域像素值异常，这些异常值参与插值计算会导致结果偏差，影响后续边缘检测准确性。王静静等^[2]先通过自适应中值滤波保留图像边缘结构信息，再对滤波后图像灰度化，计算前景与背景区域的类间方差确定最优阈值，接着用非极大值抑制方法沿梯度方向提取连续边缘，最后经形态学处理得到检测结果。但在复杂光照和噪声共同作用下，该方法检测出的

1. 郑州科技学院信息工程学院 河南郑州 450064

[15] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE transactions on pattern analysis and machine intelligence,2017,39(6):1137 - 1149.

[16] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[EB/OL]. (2017-04-19)[2026-03-16].<https://doi.org/10.48550/arXiv.1612.03144>.

电子信息科学与技术, email: 2799325027@qq.com。

蒋力畅（2004—），男，江苏徐州人，本科，研究方向：电子信息科学与技术, email: 3388718883@qq.com。

沈相同（2004—），女，山西运城人，本科，研究方向：电子信息科学与技术, email: 2969585715@qq.com。

孙敏（1981—），通信作者（email:sunmin@szcu.edu.cn），女，安徽滁州人，博士，副教授，研究方向：数字图像处理。

【作者简介】

王硕（2002—），男，江苏常州人，本科，研究方向：

（收稿日期：2025-08-19 修回日期：2026-03-17）