文章编号：2097-5899(2026)10-0040-08　　中图分类号：U298　　文献标识码：A
DOI：10.16669/j.cnki.issn.2097-5899.202509120001
引用格式：杨楠，王家祺，朱光祖，等. 面向边缘部署的改进YOLOv11铁路货运车辆轻量化检测方法[J]. 铁路物流，2026，44(10)：40-47.
YANG Nan，WANG Jiaqi，ZHU Guangzu，et al. Improved YOLOv11-Based Lightweight Detection Method for Railway Freight Vehicles for Edge Deployment[J]. Railway Logistics，2026，44(10)：40-47.

面向边缘部署的改进YOLOv11铁路货运车辆轻量化检测方法

杨　楠[1]，王家祺[2]，朱光祖[2]，王建强[2,3]

(1. 中国铁路兰州局集团有限公司 科技和信息化部，甘肃 兰州　730000；2. 兰州交通大学 交通运输学院，甘肃 兰州　730070；3. 兰州交通大学 高原铁路运输智慧管控铁路行业重点实验室，甘肃 兰州　730070)

摘　要：为了弥补传统磁钢仅能统计车辆数量、AEI技术在复杂场景下识别计数与信息匹配不精准的问题，提出一种面向边缘部署的改进YOLOv11铁路货运车辆轻量化检测方法。主要通过改进YOLOv11网络结构来进行优化：用ADown代替模型中标准卷积层提高提取图像特征的能力；将SCConv插入到颈部网络中的C3k2中降低特征图之间的冗余性实现模型轻量化；最后将EMA结合C2PSA来提升网络中相关特征的表达能力。实验表明，改进算法ASE-YOLOv11模型精确度*P*、召回率*R*、平均精度的均值*mAP*50分别为96.3%，95.2%，98.7%，同时轻量化程度也有提升，能有效实现车站内大量货运车辆的清点。

关键词：铁路货运车辆；边缘部署；轻量化；图像识别；YOLOv11

0　引言

近年来，铁路货运量不断增加，不同的铁路货运车辆如何得到有效的管理对于畅通无阻的运输是至关重要的[1]。铁路不同的货运车辆的数量统计准确与否是合理调度、优化资源配置的基础。当前传统磁钢技术仅能统计车辆数量，无法获取车型、车号等关键信息。因此，利用目标检测和深度学习的方法，辅助实现不同类型货运车辆有效快速地识别计数，具有一定价值和意义。

随着深度学习技术的不断发展，许多学者提出了基于深度学习对铁路车辆类型进行特征识别。Liu等[2]针对传统的铁路货车识别大多存在技术成本高、维护难度大等缺点，提出基于YOLOv3的铁路货车计数与识别；张超[3]采用3种不同的卷积神经网络技术，建立了基于深度学习的铁路货车车型辨识模型，并应用残差网络进一步优化处理；马传香等[4]为煤炭运输车辆设计了基于maxout+droupout的6层卷积神经网络，加强特征拟合，抑制过拟合现象，提高其泛化性能力；郑正[5]根据适配的铁路环境，使用YOLOv3识别算法，实现了识别并统计高速行驶状态下铁路车辆车型的效果；王超群[6]提出使用YOLOv4-MF模型来识别货运列车外检图像，同时引入多尺度焦点损失策略改进了YOLOv4的损失函数。虽然深度学习技术可以提升铁路货运车辆图像的识别精度，但现有研究较少考虑在保持检测精度的基础上，模型本身轻量化因素，故在云边端架构下如何部署轻量化模型是亟待解决的问题。

YOLOv11是成熟有效的检测算法，具有精度高、速度快和适应性强等特点，可应用于铁路货运车辆轻量化检测。针对边缘部署提出改进YOLOv11铁路货运

收稿日期：2025-09-12
基金项目：中国铁路兰州局集团有限公司科研项目(LZJKY2025014)

车辆轻量化检测方法，通过使用自适应下采样(Adaptive Downsampling，ADown)模块、空间和通道重建卷积(Spatial and Channel Reconstruction Convolution，SCConv)模块和加入高效多尺度注意力(Efficient Multi-Scale Attention，EMA)机制3个方案进行模型特征提取，在不降低检测精度的同时使网络轻量化，减小模型运算门槛；并通过对YOLOv11模型的一系列消融实验和对比实验，得到的实验结果表明可以提高铁路货运车辆检测的精度与效率，能够满足工业生产的铁路货运车辆检测要求，为铁路货运车辆检测提供一种有效可靠的方式。

1　YOLOv11算法原理

YOLOv11是应用于目标检测方向的一种优秀的算法，在YOLO的基础上大大提高了其准确率及速度，成为目前最主流的目标检测框架之一[7]。该算法分为主干网络、颈部网络和检测头3个部分。主干网络包括标准卷积（Conv），C3k2，SPPF，C2PSA等模块。其中C3k2继承于YOLOv8中的C2F结构，外部结构和C2F一致，内部的特征提取层由原来的Bottleneck替换为C3k。而C2PSA则是YOLOv11中新加入的一个注意力机制，位于主干网络最后位置，其首先将特征图按照金字塔的形式拆分成多个子图块，然后根据每个子图块的重要性来进行权重计算并相乘得到最终结果，这样就能让模型更注重图片的关键位置或重要信息。颈部网络也同样采用C3k2来替代原有的C2F结构，采用了高效的特征融合方法，可以很好地把多层级的信息结合起来以达到更高的目标检测效果；并且由于加入了深度可分离卷积，能有效减少模型的参数量，加快模型的速度；而且解耦的分类头和回归头的设计也能够让这两个不同的任务分开训练优化，提升整体的效果。

2　改进的YOLOv11算法框架

YOLOv11原模型更多面向通用场景设计，其结构未针对铁路货运车辆检测的特殊性及边缘部署的算力约束做适配优化：采用标准卷积层进行下采样，仅通过单一卷积操作压缩特征图空间维度，标准卷积在降低分辨率时，易丢失铁路货运车辆的关键细粒度特征，标准卷积在算力有限情况下也会导致特征提取效率难以匹配铁路货运车辆检测的精度需求；C3k2模块未针对特征冗余优化，参数量与计算量冗余不符合模型轻量化要求；C2PSA模块对多尺度特征捕捉不足，室外铁路场景若存在光照变化、复杂背景会导致原模型多尺度特征捕捉不足。

改进YOLOv11算法结构如图1所示。通过对网络结构进行优化处理，可以有效提升该算法性能，降低运算量。ADown，SCConv，EMA模块分别处于3个不同层级，实现高效协同。ADown位于主干网络前端，采用双路径设计保持车辆细粒度特征，为后续模块提供支持；SCConv嵌入颈部网络层，通过删除背景支集特征，减少计算量；EMA位于主干网络末端，承接前端优质特征，增强多尺度特征提取能力。3个模块功能上不交叠无冲突，ADown专注下采样特征保留和效率提升，SCConv专注于特征融合阶段的冗余剔除，EMA专注于注意力阶段多尺度增强，且三者均低消耗算力，互不干涉，共同支持边缘部署下“精度-效率-轻量化”平衡。算法的检测头是由深度可分离卷积(DWConv)、Conv、2维卷积(Conv2d)、分类损失(CLSLoss)和完整交并比(CIoU)组成的，它将特征提取网络输出的高维特征转化为最终的检测结果。

2.1　引入ADown下采样模块

在云边端协同场景下开展铁路货运车辆检测时，因边缘侧的算力受到限制，而参数量以及模型体积过大的情况使得其难以契合云边端对于模型轻量化的要求。运用ADown下采样模块取代原模型里的部分Conv模块[8]，既能满足边缘侧部署的条件，又能提升模型的性能。首先针对输入特征采取并行的平均池化以及最大池化手段，以此来优化特征处理的流程；接着借助平均池化来缩减特征图的空间尺寸，与此同时确保其保有一定的语义信息；随后把特征分成2条路径各自展开后续的处理，其中一条路径运用3×3卷积以高效的方式从特征当中提取出目标特征，进而达成减少网络参数的效果；另一条路径则采用3×3的最大池化方式，目的在于获取更多的图像细节特征，避免因卷积操作而引发的信息损失问题，最终经过一次1×1卷积得出新的特征图，并且对这2条分支输出的特征图予以拼接。通过引入ADown下采样模块能够最大限度地维持车辆轮廓的特征，而且还能有效缩小空间维度，从而便于在边缘侧减轻传输以及存储方面的压力。ADown结构如图2所示。

2.2　引入SCConv模块

针对实际铁路货运车辆检测场景存在的问题，在现有网络基础之上提出了一种改进方案：在C3k2架构引入自适应通道注意力机制(C3k2_SC)，以此来解决传统卷积神经网络(Convolutional Neural Networks，

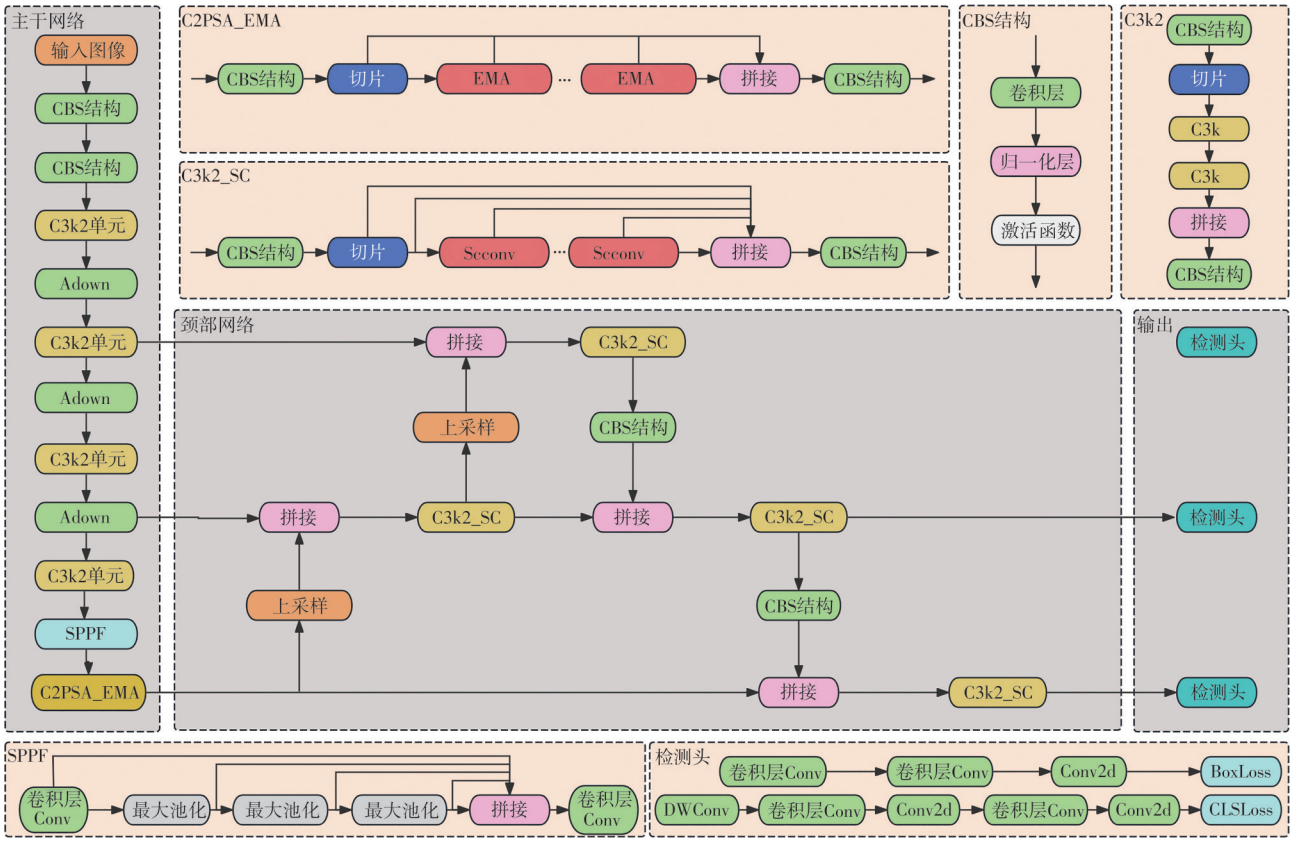

图1　改进YOLOv11算法结构

Fig.1　Improved YOLOv11 architecture

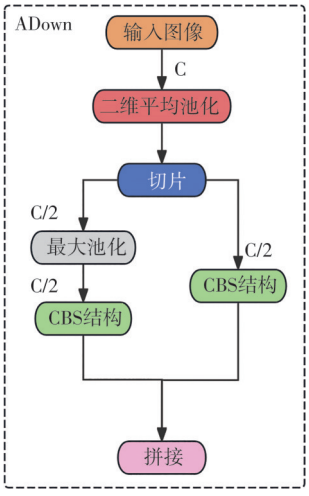

图2　ADown结构

Fig.2　ADown structure

CNNs)所面临特征冗余的问题[9]。具体来讲就是在原有网络的C3k2架构之下，把所有的C3k2都替换成C3k2_SC，并且通过增加跨阶段特征融合以及梯度截断，来进一步提升模型的性能。这2种方式能够分别提高不同层次之间特征的多样性，减少冗余的梯度信息流过模型的速度，进而保证模型仍然具有较高的检测精度，同时又能实现轻量化的网络改造。

首先，输入图像特征X经过空间重构单元，抑制空间维度中的冗余信息，得到空间细化特征X_W；随后，X_W进入通道重构单元，进一步减少通道间的冗余特征并增强有效信息，最终得到通道细化特征Y，通过空间与通道2个维度的特征重构，SCConv能够降低特征冗余并提升特征表达能力。SCConv结构如图3所示。

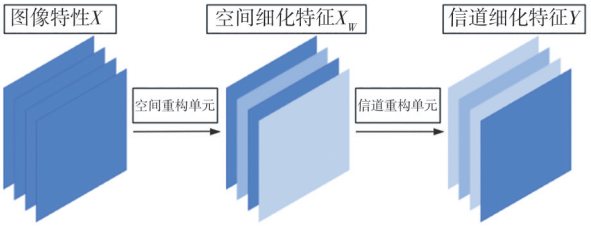

图3　SCConv结构

Fig.3　SCConv structure

2.3　引入EMA模块

由于货运车辆外形具有细粒度复杂性，且形态相似，为了提升YOLOv11原模型对于特定特征难以提取的问题，使用EMA模型[10]替换C2PSA中的普通注意

力机制，用以增强backbone的多尺度特征提取能力，EMA模块先将通道分为G组子特征，设3条并行路线。1×1卷积分支用2个一维全局平均池化层编码通道，经1×1卷积和Sigmoid激活输出两向量，重参数化聚合注意力图；EMA模块的3×3卷积分支通过3×3卷积核提取局部特征；跨空间学习模块则对二维全局平均池化输出进行Softmax线性变换拟合，将两分支输出全信息编码、激活后点积生成空间注意力图，经聚合、Sigmoid激活及自适应特征选择，为关键特征赋予更高权重，增强模型对目标车型的检测精度。EMA结构如图4所示。

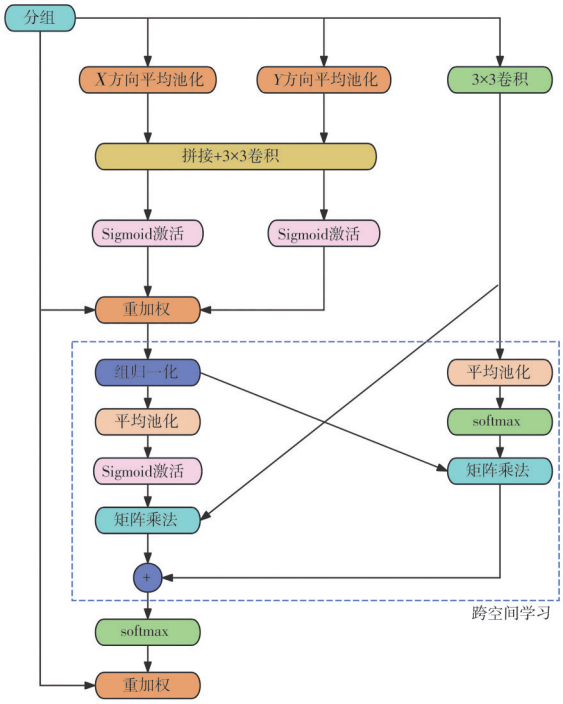

图4　EMA结构

Fig.4　EMA structure

3　实验及结果验证

为了验证提出的方法在处理车辆识别问题上的有效性，在训练模型上使用了Pycharm平台，并选用pytorch2.0.0作为深度学习框架，使用Python3.10编程软件，配置CUDA 11.8工具包。具体的硬件配置包括：操作系统Windows10；CPU型号Intel Xeon Gold 6348，内存16 G；显卡NVIDIA A40。同时在边缘设备Jetson Xavier NX Developer Kit上测试了FPS速度指标。

3.1　数据增强

为了提高铁路货运车辆图像识别模型的泛化能力和鲁棒性，针对铁路货运场景中车辆外形多变、光照条件复杂、货物遮挡等问题，设计了一种组合策略。它包括基础增强和Mosaic增强[11]：加高斯噪声，模拟传感器噪声或拍摄原因造成的图像质量下降；图像翻转模拟铁路货运场景中车辆行驶方向差异、拍摄视角镜像等情况，避免模型依赖车辆固定方向特征；灰度化能模拟低光照、恶劣天气场景，迫使模型聚焦车辆轮廓、结构等核心特征，增强色彩失真时的识别稳定性；通过网格变形，模拟车辆振动、拍摄抖动或货物表面不规则引起的形变；同时，使用四图拼接的Mosaic策略，融合不同类型、不同背景环境、不同拍摄角度的样本，增加训练数据多样性，提升对复杂货运场景的适应能力。这些策略有效扩展了数据集样本空间，涵盖不同工况、环境干扰和车辆形态变化，为模型学习车辆特征提供了丰富依据。增强后的数据集如图5所示。

3.2　实验数据集制作

Trainfanz网站作为铁路运输图像资源共享平台，其发布的铁路货运车辆图像均源自车站编组场、货运线路等实际场景，外观结构及涂装特征均符合现实铁路货运车辆形态，可准确反映目标检测所需的真实目标特征。敞车、罐车、棚车、平车4种车型是铁路货运中应用最广泛、占比最高的核心车型，几乎覆盖了散货(敞车)、液体(罐车)、怕潮怕晒(棚车)、大型设备/集装箱(平车)等主流货运场景，故利用Labelimg工具对共计548张车辆图像进行标注。为了使数据集更为丰富，通过使用数据增强技术来处理原始图像。最终得到的总数据图像2 876张。将数据集按照8∶1∶1的比例划分为训练集、测试集和验证集来验证评估模型性能。

3.3　评价指标

为了验证在边缘部署下的货运车辆识别性能，使用精确度P、召回率R、平均精度的均值、参数量、浮点运算次数(Floating Point Operations，FLOPs)和每秒帧数(FPS)对ASE-YOLOv11n模型进行评价。

精确度P表示检测正确的样本文本个数与检测结果中的正样本数目之比，取值范围为0~1，计算公式如下。

$$P=\frac{T_P}{T_P+F_P}\times 100\% \tag{1}$$

式中：T_P为已经检测到的正样本数，个；F_P为预测负样本为正样本的数量，个。

在正样本中，召回率R表示模型预测的正确比例，其计算公式如下。



a　原图片
a　Original image

b　添加噪声
b　Added noise

c　灰度化
c　Grayscale

d　水平翻转
d　Horizontal flip

e　网格变形
e　Grid distortion

f　Mosaic拼接
f　Mosaic augmentation

图5　增强后的数据集
Fig.5　Augmented dataset

$$R=\frac{T_P}{T_P+F_N}\times 100\% \tag{2}$$

式中：F_N为尚未被检测到的正样本数量，个。

平均精度的均值$mAP50$表示在交并比(IoU)阈值为0.5时各种类型A_P的平均值，反映模型在铁路货运车辆识别方面的整体性能，计算公式如下。

$$mAP50=\frac{1}{C}\sum_{i=1}^{C}A_{Pi}\times 100\% \tag{3}$$

式中：C为总计的标签分类数量，本研究车辆类型包括敞车、罐车、棚车、平车4类，故C取值为4；A_{Pi}为各类别的平均精确度。

参数量指模型中能够用于学习的参数的具体数量。一般来说，参数量较少的模型往往更为轻量化，也更加契合资源受到限制的设备。

浮点运算次数(FLOPs)是衡量模型计算量大小的指标，通过统计模型所需的浮点运算总次数反映计算复杂性。模型的FLOPs越少，计算量越小，在相同硬件环境下通常计算效率越高。

每秒帧数(FPS)为在1 s内处理的图像帧数，是衡量图像处理或模型推断速度的指标，通常用于评估计算机视觉应用程序的性能。

3.4　消融实验

以YOLOv11n原模型算法的基础在铁路货运车辆图像数据集上进行消融实验，验证ADown下采样、SCConv和EMA注意力机制3个改进点的效果，实验中的其他参数保持一致。消融实验结果如表1所示。

表1　消融实验结果
Tab.1　Ablation study results

模型	P/%	R/%	mAP 50/%	参数量/(×10^{5}个)	FLOPs/(×10^{9}次)	FPS
YOLOv11n	94.4	92.7	96.5	2.47	6.4	85.1
YOLOv11n+ADown	96.3	90.8	93.6	2.14	5.6	93.8
YOLOv11n+SCConv	92.5	93.8	96.8	2.40	6.4	83.6
YOLOv11n+EMA	93.8	89.6	96.1	2.40	6.3	93.5
YOLOv11n+ADown+SCConv	93.5	93.5	95.9	2.20	5.6	84.2
YOLOv11n+ADown+EMA	95.1	94.2	97.7	2.09	5.6	91.1
YOLOv11n+SCConv+EMA	95.2	93.7	97.4	2.36	6.4	85.6
YOLOv11n+ADown+SCConv+EMA	96.3	95.2	98.7	2.03	5.5	87.7

由表1可以看出，在主干网络中使用ADown替换Conv卷积，通过双路径拆分的轻量运算替代原始高冗余标准卷积下采样使得模型的特征提取与参数利用更加高效简洁；准确率和参数量分别优化了1.9个百分点和13个百分点，这表明ADown模块能够有效提高模型的轻量级特征提取与参数轻量化能力；添加SCConv模块使得模型召回率和*mAP*50分别提高1.1个百分点和0.3个百分点且未增加额外的计算开销，这说明SCConv模块通过空间重建与通道重建的双机制精准剔除了图片冗余特征，降低了漏检误检的风险；引入多尺度注意力机制EMA后，*P*，*R*和*mAP*50有小幅度下降，但参数量、FLOPs、FPS均有提升，EMA与ADown、SCConv进行组合后各项指标提升明显，由此可知，EMA注意力机制通过通道分组、三路径特征提取增强了网络的跨尺度信息交互，使得模型能够充分利用全局上下文来捕获目标特征，显著提升了模型的目标检测性能。最终再把这3个不同类型的模块整合为ASE-YOLOv11模型，此时的模型相较于原模型，参数量下降了18.2%，FLOPs下降了14.0%，且检测整体效果也有提升，*P*增加1.9%，*R*增加2.5%，*mAP*50增加2.2%，FPS提升了2.2%。

通过改进YOLOv11n算法并对比验证不同模块针对铁路货运车辆的识别检测结果后发现，相较于传统的YOLOv11n算法，对YOLOv11n算法的优化确保了模型的轻便性和更快的检测速度，并在准确性、召回率以及平均准确率上都实现了明显的提升，表明该模型在铁路货运车辆识别方面具有显著优势。

3.5　对比试验

为了进一步分析改进YOLOv11n算法在铁路货运车辆检测中的可行性与有效性，将其与9种算法的轻量型版本作对比，包括RT-DETR-L[12]，FasterR-CNN[13]，YOLOv3t，YOLOv5n，YOLOv8n[14]，YOLOv9t[15]，YOLOv11n以及YOLOv12n算法，并在边缘设备上进行速度测试。对照试验是在同一个铁路货运车辆数据集上完成的，对比实验结果如表2所示。

实验数据来看，FasterR-CNN的识别能力是最弱的，其精确度*P*、召回率*R*和*mAP*50都是最低的。与所有未改进模型相比，未经优化的YOLOv11n模型在铁路货物运输任务的识别上展现出了更好的性能和更高的准确性，特别适合这类的巡查和检测工作；而经过优化的ASE-YOLOv11n模型在识别能力方面表现出了更加明显的优越性，其各项性能指标都明显优于其他模型。与YOLO系列模型相比，本研究提出的模型不仅增强了检测的准确性，降低了误检和漏检的可能性，而且在整体检测性能方面表现得尤为出色。通过以轻量级目标检测为核心，边界框统计为计数方式的技术路线，能够有效地辅助解决车辆漏检和误检的问题。可视化对比图如图6所示。

4　结束语

研究结果表明，ASE-YOLOv11n在铁路货运车辆检测中兼顾识别精度、推理速度与模型轻量化，综合性能优于现有目标检测模型，具备边缘部署潜力。该方法可提升铁路场景下车辆识别与计数的可靠性，为弥补传统磁钢信息获取单一及AEI在复杂工况下匹配

表2　对比实验结果

Tab.2　Comparative experimental results

算法	*P*/%	*R*/%	*mAP*50/%	参数量/(×10^{5}个)	FLOPs/(×10^{9}次)	FPS
FasterR-CNN	78.5	74.2	81.3	130.3	203.2	2.3
RT-DETR-L	85.0	69.9	81.9	31.29	108.0	8.6
YOLOv3t	86.4	85.7	94.5	10.43	17.7	15.4
YOLOv5n	93.9	89.7	96.6	2.39	7.2	20.5
YOLOv8n	94.0	94.2	96.3	2.87	8.2	23.5
YOLOv9t	94.0	90.8	96.4	2.06	7.9	23.8
YOLOv10n	85.1	81.4	91.6	2.58	8.4	18.4
YOLOv11n	94.4	92.7	96.5	2.47	6.4	25.1
YOLOv12n	94.3	92.2	96.6	2.45	6.4	25.3
改进YOLOv11n	96.3	95.2	98.7	2.03	5.5	25.9



a　原图
a　Original image

b　YOLOv5n检测结果
b　YOLOv5n detection result

c　YOLOv9t检测结果
c　YOLOv9t detection result

d　YOLOv11n检测结果
d　YOLOv11n detection result

e　YOLOv12n检测结果
e　YOLOv12n detection result

f　ASE-YOLOv11n检测结果
f　ASE-YOLOv11n detection result

图6　可视化对比图

Fig.6　Visual comparison of detection results

精度不足提供技术路径，也为铁路货运智能感知与云边端协同应用提供参考。后续研究将结合现场运行环境，进一步评估模型在不同光照、遮挡及设备算力条件下的稳定性与泛化能力，并优化检测性能、模型规模和部署成本之间的平衡，推动其在铁路运输生产中的工程化应用。

参考文献：

[1] XIN X Y. Service Network Design for Freight Railway Transportation: The Chinese Case[J]. PLoS One，2022，17(12)：e0276671.

[2] LIU Z H，WANG Z M，XING Y X. Wagon Number Recognition Based on the YOLOv3 Detector[C]//2019 IEEE 2nd International Conference on Computer and Communication Engineering Technology (CCET). Beijing：IEEE，2019：159-163.

[3] 张　超. 基于深度学习的铁路货车类型识别研究[D]. 北京：北京交通大学，2019.

[4] 马传香，汪炀杰，王　旭. 基于卷积神经网络的煤炭运载车辆识别[J]. 计算机科学，2020，47(S2)：219-223.
MA Chuanxiang，WANG Yangjie，WANG Xu. Identification of Coal Vehicles Based on Convolutional Neural Network[J]. Computer Science，2020，47(S2)：219-223.

[5] 郑　正. 基于YOLOv3神经网络的轨道车辆识别技术研究[J]. 智慧轨道交通，2022，59(1)：34-38.
ZHENG Zheng. Preliminary Study on Railway Vehicle Recognition Technology Based on YOLOv3 Neural Network[J]. Intelligent Rail Transit，2022，59(1)：34-38.

[6] 王超群. 基于深度学习的货运列车外检图像识别技术研究[D]. 沈阳：东北大学，2021.

[7] 李　彬，李生林. 改进YOLOv11n的无人机小目标检测算法[J]. 计算机工程与应用，2025，61(7)：96-104.
LI Bin，LI Shenglin. Improved YOLOv11n Small Object Detection Algorithm in UAV View[J]. Computer Engineering and Applications，2025，61(7)：96-104.

[8] WANG C Y，YEH I H，MARK LIAO H Y. YOLOv9：Learning What You Want to Learn Using Programmable Gradient Information [C]//Computer Vision-ECCV 2024. Cham：Springer，2025：1-21.

[9] LI J F，WEN Y，HE L H. SCConv：Spatial and Channel Reconstruction Convolution for Feature Redundancy[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 17-24，2023，Vancouver：IEEE，2023：6153-6162.

[10] OUYANG D L，HE S，ZHANG G Z，et al. Efficient Multi-Scale Attention Module with Cross-Spatial Learning[C]//ICASSP 2023—2023 IEEE International Conference on Acoustics，Speech and Signal Processing (ICASSP).Rhodes Island：IEEE，2023：1-5.

[11] 杨　豚，郭永存，王　爽，等. 煤矿井下无人驾驶轨道电机车障碍物识别[J]. 浙江大学学报(工学版)，2024，58(1)：29-39.
YANG Tun，GUO Yongcun，WANG Shuang，et al. Obstacle Recognition of Unmanned Rail Electric Locomotive in Underground Coal Mine[J]. Journal of Zhejiang University (Engineering Science)，2024，58(1)：29-39.

[12] ZHAO Y A，LV W Y，XU S L，et al. DETRs Beat YOLOs on Real-Time Object Detection[C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle：IEEE，2024：16965-16974.

[13] WANG Z B，BAI L，SONG G F，et al. Optimized Faster R-CNN

for Oil Wells Detection from High-Resolution Remote Sensing Images[J]. International Journal of Remote Sensing，2023，44(22)：6897-6928.

[14] VARGHESE R，M S. YOLOv8：A Novel Object Detection Algorithm with Enhanced Performance and Robustness[C]//2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS). Chennai：IEEE，2024：1-6.

[15] WANG C Y，YEH I H，MARK LIAO H Y. YOLOv9：Learning What You Want to Learn Using Programmable Gradient Information [M].Cham：Springer Nature Switzerland，2024.

（责任编辑：刘宁馨）

Improved YOLOv11-Based Lightweight Detection Method for Railway Freight Vehicles for Edge Deployment

YANG Nan[1]，WANG Jiaqi[2]，ZHU Guangzu[2]，WANG Jianqiang[2,3]

(1. Department of Science，Technology and Information Technology，China Railway Lanzhou Group Co.，Ltd.，Lanzhou 730000，Gansu，China；2. School of Traffic and Transportation，Lanzhou Jiaotong University，Lanzhou 730070，Gansu，China；3. Key Laboratory of Intelligent Management and Control for Plateau Railway Transportation in the Railway Industry，Lanzhou Jiaotong University，Lanzhou 730070，Gansu，China)

Abstract: To address the limitations of conventional magnetic steel sensors, which can only count the number of railway vehicles, as well as the inaccurate vehicle identification, counting, and information matching of automatic equipment identification (AEI) systems under complex operating conditions, a lightweight YOLOv11-based railway freight vehicle detection method was proposed for edge deployment. The YOLOv11 architecture was optimized in three aspects. First, the standard convolutional layers were replaced with ADown blocks to enhance the image feature extraction capability of the network. Second, spatial and channel reconstruction convolution (SCConv) was incorporated into the C3k2 module of the neck network to reduce redundancy among feature maps and achieve a lightweight model. Finally, the efficient multi-scale attention (EMA) module was integrated with C2PSA to enhance the representation capability of relevant features in the network. Experimental results show that the improved ASE-YOLOv11 model achieves a precision (P) of 96.3%, a recall (R) of 95.2%, and an mAP50 of 98.7%, while also achieving further model lightweighting. The proposed method can effectively count large numbers of railway freight vehicles in railway stations.

Keywords: Railway Freight Vehicles; Edge Deployment; Lightweighting; Image Recognition; YOLOv11