Defect detection of EMU bogie bolts based on deep learning

Zhiyong Li[1,2,3], Gang Peng[1,2,3,*], Zhonghua Deng[1,2,3], ChaoZe Wang[1,2,3], Chaowei Song[1,2,3], Mingjun Chong[1,2,3], Zhang Deng[4], Xinbin Xiong[4], Chong Li[5]

[1)] School of Artificial Intelligence and Automation, Huazhong University of Science and Technology, Wuhan 430074
[2)] Key Laboratory of Image Information Processing and Intelligent Control, Ministry of Education, Wuhan 430074
[3)] Engineering Research Center of Autonomous Intelligent Unmanned Systems, Ministry of Education, Wuhan 430074
[4)] Beijing Railway Engineering Electromechanical Technology Research Institute Co., Beijing 100071
[5)] Wuhan Lisai Technology Co., Wuhan 430073

***Abstract*—After long-term high-speed operation of the EMU, bolts may become loose or lost, which seriously threatens the safe operation of the EMU. Therefore, the daily maintenance of the bogie bolts of the EMU is very important. In view of the current problems of manual maintenance workload, low efficiency, and prone to missed detection and incorrect detection. This paper proposes a bolt defect detection algorithm that combines images and point clouds. First, YOLOv8, which adds a coordinate attention mechanism, is used on the image to locate the bolt area and identify missing bolts. Then the RANSAC algorithm with normal vector constraints is used to segment the bolt area point cloud to obtain the upper surface of the bolt and the bolt installation datum. Finally, bolt loosening detection is achieved by calculating the distance between the two planes and comparing it with the threshold. Experiments show that in terms of bolt positioning, compared with the original YOLOv8s, the improved algorithm in this article has improved mAP0.5 and mAP0.5:0.95 by 0.8% and 1.3% respectively; in the detection of loose bolt defects, the accuracy rate has reached 93.1% and the recall rate reached 100%. The bolt defect detection algorithm proposed in this article can meet the needs of EMU inspection tasks.**

***Keywords*—defect detection, target detection, attention mechanism, point cloud**

基于深度学习的动车组转向架螺栓缺陷检测

李志勇[1,2,3] 彭刚[1,2,3,*] 邓忠华[1,2,3] 王超泽[1,2,3] 宋朝位[1,2,3] 从明均[1,2,3] 邓张[4] 熊歆斌[4] 李聪[5]

[1)] 华中科技大学人工智能与自动化学院，武汉 430074，中国
[2)] 图像处理与智能控制教育部重点实验室，武汉 430074，中国
[3)] 自主智能无人系统教育部工程研究中心，武汉 430074，中国
[4)] 北京铁道工程机电技术研究所股份有限公司，北京 100071，中国
[5)] 武汉黎赛科技有限责任公司，武汉 430073，中国

摘 要 动车组在长期高速运行后会出现螺栓松动、丢失等风险，严重威胁到动车组的安全运行，因此对于动车组转向架螺栓的日常检修显得十分重要。针对目前人工检修工作量大、效率低、容易存在漏检误检的问题。本文基于深度学习，提出一种结合图像和点云的螺栓松动检测算法。首先在图像上利用添加坐标注意力机制的 YOLOv8 进行螺栓区域定位以及丢失螺栓的识别。然后对定位到的螺栓区域进行点云映射，获得螺栓区域点云。接着采用带有平面方向约束的 RANSAC 算法对螺栓区域点云进行分割，获取螺栓上表面以及螺栓安装基准面。最后通过计算两平面的距离并与阈值进行对比，实现螺栓松动检测。实验表明在螺栓定位上，本文改进的算法相较于原始的 YOLOv8s，mAP0.5 和 mAP0.5:0.95 分别提升了 0.8%和 1.3%；在螺栓松动缺陷检测中查准率达到了 93.1%，查全率达到了 100%。本文所提出的螺栓松动检测算法可以满足动车组巡检任务需求。

关键词 缺陷检测，目标检测，注意力机制，点云

1．引言

随着我国高速铁路的不断发展，铁路运行里程不断增加，运行速度更是达到了 350km/h。为了保证动车组的安全运行，其日常巡检变得十分重要，螺栓作为动车转向架中分布最广、数量最多的零部件，在动车组长期高速运行后会出现松动、丢失等风险，严重威胁到动车组的安全运行。目前为止，针对动车组转向架检修，我国主要的采用方式为人工巡检，此方式需要耗费大量的人力且检测效率不高，容易造成漏检误检等问题。基于机器视觉的检修方式具有检测效率高、不容易受环境影响的优点，为动车组检修提供了新的策略。

目前国内外学者已经对螺栓松动检测展开了一系列的研究。杨培盛等人提出一种基于深度学习的地铁车体螺栓松动检测算法[1]，首先利用 YOLOv3 对螺栓区域进行定位，然后利用 U-net 语义分割模型螺栓表面防松标记线进行分割，并对标记线进行直线拟合，最后根据直线的倾斜程度来判断螺栓是否发生松动。该方法适用于表面有防松标记线的螺栓松动检测，但是在实际情况下，大部分螺栓不包含防松标记线，而且在有防松标记线的情况下也会因为灰尘、污渍等原因导致标记线不清晰。因此该方法有一定局限性。Sun J 等人提出一种基于双目视觉的列车关键部件螺栓松动快速检测方法[2]，利用卷积神经网络结合列车关键部件结构化的分布规律，由粗到细的定位螺栓并分割螺栓表面的亚像素边缘，最后通过双目视觉的方式计算螺栓表面的距离即可判断螺栓的状态。杨绿溪等人提出了一种基于深度学习和霍夫变换的六边形螺栓松动检测方法[3]，首先对输入图片计算深度特征得到螺栓位置，然后在原始图像中根据螺栓位置结合一系列图像处理算法得到边缘信息，最后利用霍夫变换计算螺栓角度，从而判断螺栓是否发生松动。Hao Gong 等人提出一种结合深度学习和几何成像理论的螺栓松动检测算法[4]，利用 Faster-RCNN 来进行螺栓区域定位，然后采用级联金字塔网络（CPN）进行螺栓上的五个关键点的检测，在五个关键点的基础上结合相机参数计算出外露螺栓长度，进而判断螺栓是否松动。Deng X 等人提出一种带标记线的螺母松动检测算法[5]，利用 Keypoint-RCNN 对螺帽定位的同时，输出螺帽上预先标定的五个关键点，并结合几何成像理论，计算得到了螺帽的松动角度。卢海林等人提出了一种基于三维点云处理的螺栓松动检测算法[6]，对目标点云进行下采样和离群点的移除，然后根据欧式距离对点云进行聚类分割，计算分割后每个点云包围盒形状系数和平均 Z 坐标，实现螺栓点云定位，最后通过采样一致性算法拟合点云平面计算出螺栓松动程度，识别螺栓故障。这些方法均无法有效应用于动车转向架巡检场景螺栓松动检测。

针对动车转向架场景，本文基于深度学习，提出一种结合图像和点云的螺栓松动检测算法。首先在图像上利用改进的 YOLOv8 进行螺栓区域定位，然后利用定位到的螺栓区域进行点云映射获取螺栓区域三维点云，接着采用带有平面方向约束的 RANSAC 算法对该三维点云进行分割获取螺栓上表面以及螺栓安装基准面，最后通过计算两平面的距离并与阈值进行对比，来实现螺栓松动检测。本文所提出的方法对检测项点拍摄角度不严格限制，且利用图像区域定位与点云分割相结合的方式，有较高的检测效率与准确率。本文主要的贡献有以下几点：

(1)本文的方法结合图像和点云信息进行螺栓松动检测，克服了仅使用图像无法有效检测螺栓松动，以及仅使用点云计算量大的问题。可以实时有效的检测到螺栓的松动。

(2)利用坐标注意力机制（CA）对 YOLOv8 进行优化，提高了螺栓定位的精度。

(3)提出一种带平面方向约束的 RANSAC 算法对螺栓区域点云进行分割，避免许多无效运算，提高了算法的检测效率。

2．相关工作

2.1 目标检测

当前主流的利用深度学习进行目标检测的方法通常分为一阶段（One Stage）和两阶段（Two Stage）两种。他们主要的区别是，两阶段的目标检测是在特征提取的基础上，通过区域建议网络（Region Proposal Network，RPN）提取出图像中可能存在目标的感兴趣区域（Region of Interesting, ROI），然后对一系列候选框进行分类和回归。而一阶段目标检测网络直接在特征提取的基础上进行目标框的分类和回归。两阶段目标检测具有代表性的方法主要有 R-CNN[7]、Fast-RCNN[8]、Faster-RCNN[9]，一阶段目标检测具有代表性的有 YOLO[10]系列、SSD[11]、RetinaNet[12]等。

YOLO 系列算法作为经典的一阶段目标检测算法，经过多个版本的不断改进，检测速度和精度不断提高。YOLOv8 网络结构主要可以分为 3 个部分：主干特征提取网络、颈部网络、头部网络。其中主干特征网络负责对输入的图像进行特征提取；颈部负责对主干网络提取的不同层次的特征进行融合，并输出大中小三种尺度的特征图用于后续的预测。头部为整个模型的预测端，利用融合后的特征通过卷积的方式得出模型的预测结果，包括目标的预测边界框与类别。目前的 YOLOv8 引入了新的功能和改进，相比于 YOLO 系列的其他算法，YOLOv8 的改进主要有以

下几点：

(1)抛弃了以往的 Anchor-Base，使用了 Anchor-Free 的思想。

(2)将原模型中使用的 C3 模块替换成 C2f 模块，使模型进一步轻量化。

(3)头部采用解耦头方式，将目标框的回归与目标分类任务相解偶，该方式允许模型分别对分类和定位任务进行优化。

(4)抛弃了以往的 IOU 匹配或者单边比例的分配方式，而是使用了 Task-Aligned Assigner 匹配方式。

YOLOv8 根据模型参数量的不同分为 n、s、m、l、x 五个不同模型，在权衡检测精度与检测速度的基础上，选择 YOLOv8s 作为螺栓区域检测的基线算法，并对其进行改进。

2.2 CA 注意力

坐标注意力（Coordinate Attention, CA）[13]引入了位置编码机制，通过将位置信息嵌入到通道注意力中，使得轻量级网络能够在更大的区域上进行注意力，同时避免了产生大量的计算开销。CA 注意力机制模块结构如图 1 所示，其采用两个一维特征编码操作，分别沿水平坐标方向和竖直坐标方向对每个通道进行编码得到一对方向感知注意力特征图，该方法在提取通道注意力的同时对位置信息敏感。在提取两个方向的编码信息后，对其进行空间维度上的拼接，接着采用一个 1×1 的卷积进行通道维度的信息交互与压缩，然后在空间维度将获得的特征图进行切分。切分后的特征图分别经过 1×1 的卷积将通道数恢复到与原始特征图相同并进行归一化来获取空间维度两个方向的注意力权重，最后将原始特征图分别与注意力权重相乘并融合，获得最终输出的特征图。

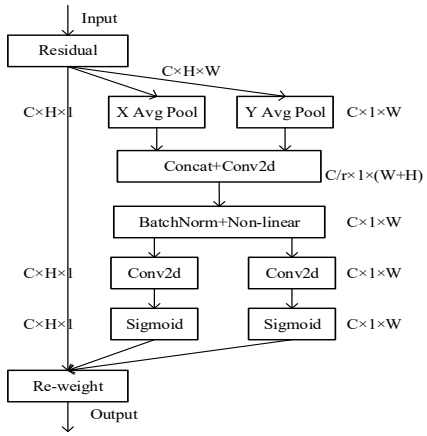

图 1　CA 注意力机制

3．本文方法

3.1　算法整体框架

本文提出的基于图像和点云的螺栓缺陷识别算法主要分为两大部分：螺栓定位与丢失识别，螺栓松动识别。第一阶段利用本文改进的 Yolov8 进行螺栓的区域定位，同时可以识别螺栓丢失情况下的螺栓孔洞。第二阶段螺栓松动识别是在识别到螺栓存在的基础上，进行螺栓区域裁剪并映射到三维点云，获取螺栓区域点云数据。然后分别利用 RANSAC 算法以及带有平面方向约束的 RANSAC 算法进行两次点云平面分割。获取螺栓上表面与安装基准面。最后计算两平面的距离并与设定的阈值相比较，从而判断该螺栓是否发生松动。算法的整体框图如图 2 所示。

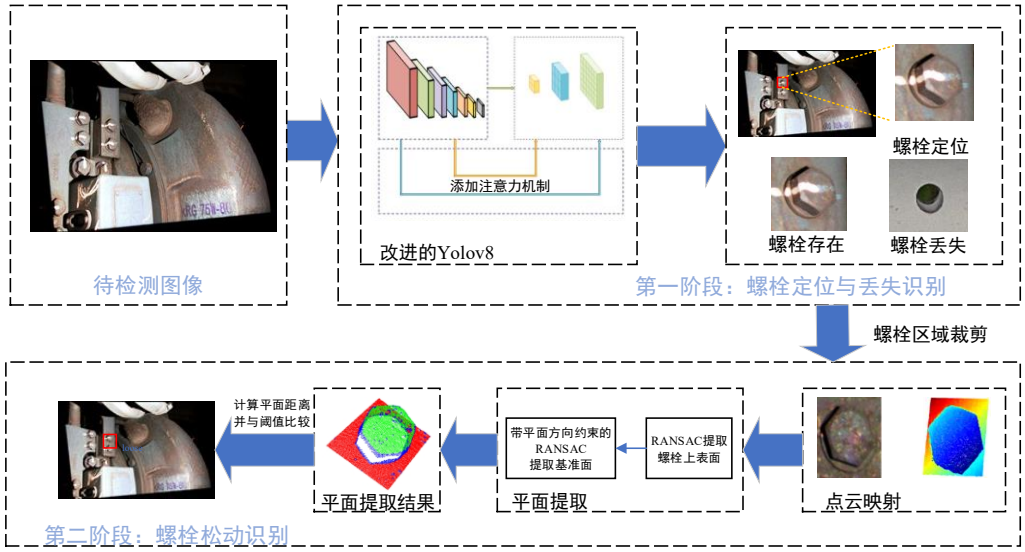

图 2　基于图像和点云的动车转向架螺栓松动检测算法整体框架

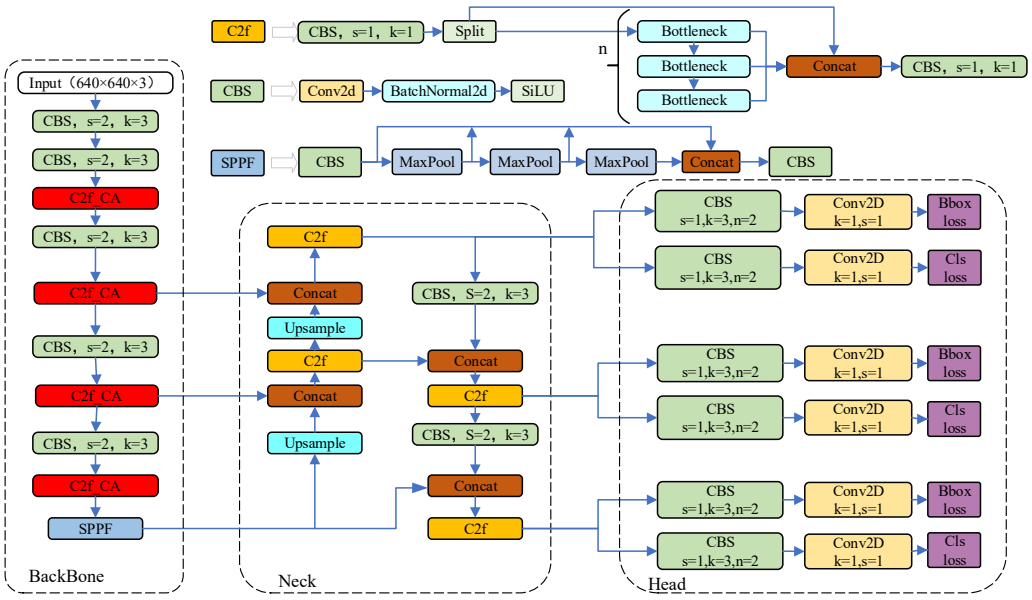

图 3　改进 YOLOv8 结构图

3.2　基于改进的 YOLOv8 螺栓定位与丢失识别

针对动车转向架底部零部件复杂，背景干扰物多、螺栓特征不明显等问题，本章提出一种基于改进 YOLOv8 的转向架螺栓定位与丢失识别方法，其整体结构如图 3 所示。C2f 作为 YOLOv8 特征提取中的重要的一个基础模块。其残差结构虽然可以在一定程度缓解随着网络深度增加而出现的梯度消失问题，但是对于背景包含与目标特征相似的区域时目标检测的效果较差。为了改善针对动车转向架底部螺栓检测的效果，本文在 C2f 模块中添加 CA 注意力机制。由图 3 可以看出 C2f 模块主要是由多个 Bottleneck 模堆叠，本文在 Bottleneck 模块中添加 CA 注意力机制并命名为 Bottleneck_CA，添加注意力前后的 Bottleneck 结构如图 4 所示：

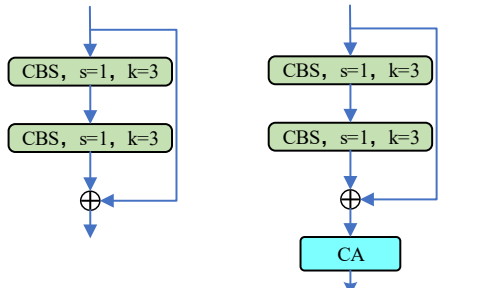

（a）Bottleneck　　（b）Bottleneck_CA

图 4　添加注意力前后的 Bottleneck 结构图

3.3　基于 RANSAC 平面分割的螺栓松动检测

三维空间中平面的表示方程为 $Ax+By+Cz+D=0$，也就是说三维空间中平面模型有 A、B、C、D 四个参数，确定一个平面至少需要三组坐标点。利用 RANSAC 算法进行点云平面分割具体步骤如下：

（1）在螺栓区域点云中随机选取 3 个点 (x_1,y_1,z_1)、(x_2,y_2,z_2)、(x_3,y_3,z_3) 作为内点集合，并计算临时三维平面的模型参数 A、B、C、D。

（2）依次遍历剩下的数据点 (x_k,y_k,z_k)，计算点到本次迭代平面的距离 h，如果 h 小于设定的阈值 H 则将该点加入内点集合。

（3）重复上述过程并选择内点数量最多的模型，当达到模型设定的模型迭代次数，或者内点数量达到一定数目时停止迭代。

（4）返回迭代的内点集合以及模型参数 。

其中模型参数 A、B、C、D 和点到平面的距离 h 的计算公式如下所示：

$$A=(y2-y1)*(z3-z1)-(z2-z1)*(y3-y1) \quad (1)$$

$$B=(z2-z1)*(x3-x1)-(x2-x1)*(z3-z1) \quad (2)$$

$$C=(x2-x1)*(y3-y1)-(y2-y1)*(x3-x1) \quad (3)$$

$$D=-(A*x1+B*y1+C*z1) \quad (4)$$

$$h=\frac{|Ax_k+By_k+Cz_k+D|}{\sqrt{A^2+B^2+C^2}} \quad (5)$$

利用点云进行螺栓松动检测需要进行两次平面分割，分别提取螺栓上表面和安装基准面。第一次 RANSAC 算法平面分割可以提取出在点云中占比重较大的螺栓上表面，然后对剩余的点云数据点进行第二次平面分割。考虑到两次提取的平面应该相互平行这一先验知识，所以在进行第二次分割时加入平面方向的约束项。具体的实现方式是在 RANSAC 算法点云平面的分割步骤（1）后面添加一个步骤：计算本次迭代数据点所确定的平面与第一次点云分割确定的平面之间的余弦值 cos，当 cos>0.995 时继续进行下一步骤，否则返回步骤（1）重新选取新的随机点进行下一次迭代。

经过实验确定两次点云平面提取中设置的最大迭代次数（MaxIterations）为 100，距离阈值 H 为 0.1。在第二次平面提取时加入平面方向约束项，可以减少无效运算量，提高算法的检测效率。利用 RANSAC 进行平面分割的效果如图 5 所示：

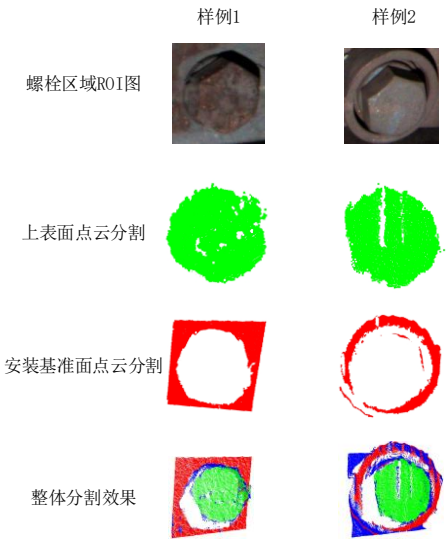

图 5　点云平面分割示意图

4．实验结果与分析

4.1　数据集构建

本文所采用的图像数据是由巡检机器人上安装的机械臂末端的深度相机拍摄的。部分待检测图像示例如图 6 所示。使用 LabelImg 对数据集进行标注，标注的类别包含 Bolt 与 Lost_Bolt 两类，采用 VOC 数据集的格式对图像进行存放。

在巡检机器人在巡检工位停靠时，不可避免的会有一定的距离误差，这会导致同一巡检点位的图像视野存在一定的平移误差。同时机械臂的轻微抖动，可能会造成图像呈现一定的噪声。为了使训练网络所使用的数据集尽可能的覆盖真实情况下采集数据的分布，同时缓解样本不足的问题。采用平移变换、旋转变换、亮度调整、添加噪声等方式对原始数据进行增强。图像增强具体参数设置如表 1 所示：

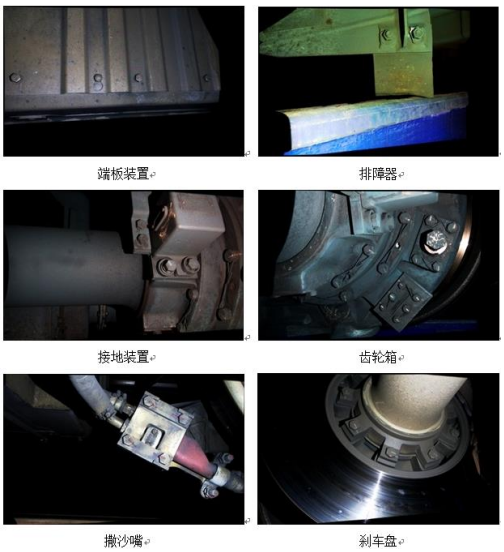

图 6　部分待检测图像示例

表 1 数据增强参数设置

增强方式	参数范围	参数解释
平移	±20 pix	水平/垂直方向平移像素
旋转	±5 度	旋转角度
亮度调整	75%~125%	亮度调整百分比
高斯噪声	μ :0, δ :0.05	高斯分布的均值与标准差
椒盐噪声	0.01%~0.02%	随机噪声像素比例

为了防止在数据增强后再进行训练验证集的划分，导致模型的过拟合，本文首先将 982 张原始图像随机挑选 700 张作为训练集，剩余 282 张作为验证集，进行一次数据集划分。然后对训练集图像进行数据增强，随机选取增强方式对每一张训练图像进行变换将训练集扩充至原来的 3 倍，最后得到训练集图像一共 2100 张。为了防止训练集与验证集图像数量差异太大导致无法反映模型的好坏，将验证集扩充至原来的 2 倍，一共得到 564 张验证集图像。

4.2　评价指标

在螺栓定位实验中采用精确度（Precision, P）、召回率（Recall, R）、平均精度（Average precision, AP）、平均精度均值（mAP）以及每秒帧数（FPS）作为评价指标来评价模型的整体性能，计算公式如下

$$P=\frac{TP}{TP+FP} \tag{6}$$

$$R=\frac{TP}{TP+FN} \tag{7}$$

式中，TP 表示正类被预测为正类的样本数，FP 表示负类被预测为正类的样本数，FN 表示正类被预测为负类的样本数。

$$AP=\int_0^1 P(R)dR \tag{8}$$

$$mAP=\frac{\sum_{m=1}^{M} AP}{M} \tag{9}$$

式中 AP 表示 PR（Precision-Recall）曲线所围成区域的面积，M 表示数据集中所有类别的数目。

4.3 实验环境与参数设置

本文对改进的 YOLOv8 网络的训练和验证环境如表 2 所示：

表 2：实验环境配置

软/硬件环境	具体配置
操作系统	Linux（Ubuntu 18.04）
CPU 型号	Intel(R) Core(TM) i7-7700K @ 4.50GHz
GPU 型号	NVIDIA TITAN Xp（12G）
内存	32G
开发语言	Python3.7
深度学习框架	PyTorch v1.10
CUDA 环境	CUDA10.2 和 CuDNN10.2

模型训练采用加载预训练权重的方式，训练时的一些关键参数如表 3 所示：

表 3：模型训练时的一些关键参数设置

参数名称	参数设置
训练轮次	30
批大小	8
优化器	SGD
动量	0.937
学习率	0.01
权重衰减	0.0005
图像尺寸	640×640

4.4 螺栓定位实验

为了验证本文所改进的模型在动车转向架数据集上相比于其他经典目标检测模型的优越性，在保证其他训练条件一致的情况下，验证对比了 Faster R-CNN、YOLOv5s、YOLOv6s、RT-DETR、YOLOv8s 与本文所提方法的检测精度与速度，对比结果如表 4 所示：

表 4：不同模型检测精度对比

模型	mAP0.5/%	mAP0.5:0.95/%	FPS
Faster R-CNN	91.7	51.2	10
YOLOv5s	91.5	50.2	139
YOLOv6s	89.2	49.7	112
RT-DETR	87.3	47.5	50
YOLOv8s	92.7	51.5	116
改进的 YOLOv8s	**93.5**	**53.8**	114

由表4中数据看本文改进的YOLOv8s在检测精度上均优于其他几种算法，相比于原始的 YOLOv8 mAP0.5 和 AP0.5:0.95 分别提升了 0.8%和 1.3%，虽然 FPS 小于 YOLOv5s 的 139 帧，但是 mAP0.5 和 AP0.5:0.95 相较于 YOLOv5s 分别提升了 2.0%和 3.6%。综合考虑到检测精度和检测效率的平衡，本文所提出的算法能够更好的满足动车巡检场景下的螺栓检测任务。

模型改进前后检测效果如图 7 所示：

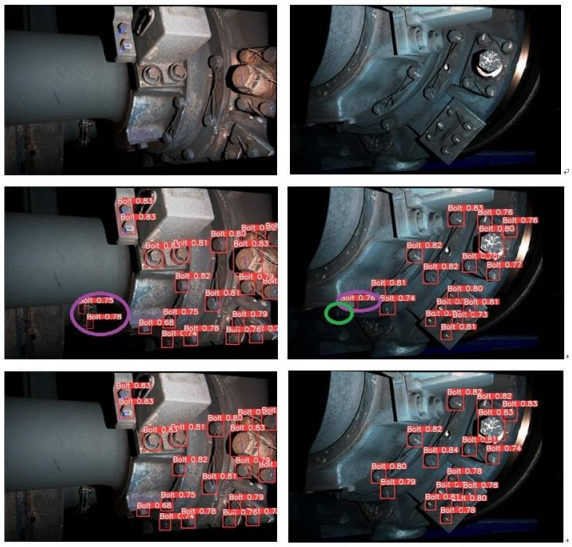

图 7　模型改进前后检测效果

图 7 中第一到三行分别代表原始图像、YOLOv8 检测结果、本文所改进的模型的检测结果。其中绿色圆圈表示模型改进前的漏检目标，紫色圆圈表示误检目标。通过对比可以发现，本文改进的模型，不仅可以减少小尺寸和图像特征不明显螺栓的漏检，同时可以降低背景中与检测目标特征相似区域的误检。

4.5 螺栓松动检测实验

由于 RANSAC 算法是一个需要不断遍历所有数据点的算法，所以点云的稠密程度直接影响了算法的运行效率。本文对比了不同下采样倍数下的平面提取后平面距离的平均测量误差，以及单个螺栓的平均处理运行时间，实验统计结果如表 5 所示。

表 5：不同下采样倍数实验对比

下采样倍率	平均测量误差/mm	平均处理时间/s
1	0.14	34.69
2	0.15	3.02
4	0.17	0.39
8	0.79	0.08

由表 5 可以看出，在不进行下采样的情况下，算法的平均测量误差最低为 0.14mm，但是该倍率下单个螺栓的处理时间达到了 34.69s，该检测速度远远不能满足动车巡检场景下的螺栓缺陷检测任务；在 4 倍下采样的情况下，测量值的平均误差为 0.17mm，运行时间为 0.39s；而 8 倍下采样下，虽然单个螺栓的处理时间进一步缩减到 0.08s，但是算法的平均测量误差达到了 0.79mm，无法满足螺栓松动检测任务的实际需求。

不同下采样倍数下的平面分割情况如图 8 所示：

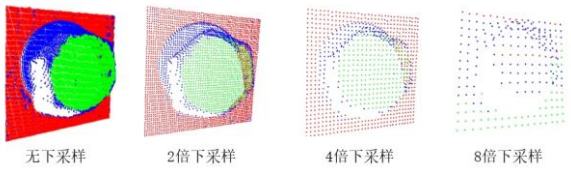

图 8　不同下采样倍率下的平面分割结果

由图 8 可以看出，在 8 倍下采样的情况下，点云平面的分割已经不能实现螺栓上表面和安装基准面的正常提取，这也是螺栓平面的检测误差在该下采样倍数下陡升到 0.79mm 原因，所以综合考虑平均测量误差与运行效率，最终选择对点云进行 4 倍下采样处理。

在利用测量得到的螺栓上表面与测量基准面之间的距离，进行螺栓松动缺陷的判断时，由于存在一定的测量误差，所以不能直接将测量值大于螺栓紧固状态下的标准值的螺栓确定为松动类缺陷。需要设定一个阈值，如果测量值大于该标准值+阈值，则判定该螺栓为松动。不同阈值的设定会导致漏检，误检数量的变化，因此本文随机挑选 300 个螺栓其中包含不同松动程度的螺栓 40 个，以查准率和查全率作为评价指标进行实验，对比了不同阈值下的松动检测情况。不同阈值下的检测结果如表 6 所示：

表 6：不同设定阈值的螺栓松动检测结果

阈值/mm	误检/个	漏检/个	查准率（%）	查全率（%）
0.05	20	0	66.7	100.0
0.15	3	0	93.1	100.0
0.30	1	2	97.4	95.0
0.45	0	7	100.0	82.5

表中查全率为检测出来的真实缺陷占所有缺陷的比例，查准率为检测出来的真实缺陷占所有检测出来缺陷的比例。

由表 6 中数据可以看出随着设定阈值的增大，误检率在降低，漏检率在升高。从而导致查准率越来越高，而查全率在越来越低。因为随着阈值的增大，正常螺栓被判定为松动螺栓的概率越来越小，而相应的松动螺栓被判定为正常螺栓的概率越来越大。在本文方法中查准率与查全率是一个互相矛盾的存在，不能同步提高，只能选取一个折中的效果。而缺陷检测任务要求是尽可能将所有的缺陷检测出来，所以要求在最小漏检率的前提下，保证误检率尽可能小。因此当阈值设定为 0.15mm 时为最佳选择，此时查全率达到了 100%，而且查准率也达到了 93.1%。

最后将本文所提出的方法与其他方法进行对比。

方法 1：直接将螺栓松动检测作为目标检测问题，即将松动螺栓当作一个目标类别，对 YOLOv8 进行训练，并验证；

方法 2：同样采用两阶段的方式进行螺栓松动检测。利用 YOLOv8 螺栓定位，结合 Reset 分类网络对螺栓分类来实现螺栓松动检测。不同方法的实验对比结果如表 7 所示：

表 7：不同方法的螺栓松动检测实验

方法	查准率/%	查全率/%
YOLOv8	16.1	22.5
YOLOv8+Reset 分类	20.7	27.5
本文方法	**93.1**	**100**

根据表 7 可以看出，YOLOv8 或者 YOLOv8+Resnet 分类的方法，其查准率和查全率都未达到 30%。通过分析实验结果得出，该两种方法均只能识别出松动程度较大的螺栓，这样无法满足任务要求。而本文的方法则可以识别

出松动程度较低的螺栓，在松动缺陷中查全率达到了100%，很好的满足了任务的要求。

部分螺栓缺陷识别结果如图 9 所示：

图 9　螺栓缺陷识别结果图

5．结论

本文针对动车转向架底部螺栓缺陷识别任务需求，基于深度学习，提出一种结合图像与点云信息的高铁动车转向架螺栓缺陷检测方法。该方法首先利用添加 CA 注意力机制的 YOLOv8 模型进行螺栓定位以及丢失螺栓的识别。然后在定位螺栓的基础上进行点云映射获得螺栓区域点云。接着采用带平面方向约束的 RANSAC 算法进行点云平面分割，根据分割所得的螺栓上表面和安装基准面计算距离。最后根据测量的距离与标准的距离值进行对比，即可判断螺栓是否发生松动。实验结果表明，在螺栓定位上，本文改进的算法相较于原始的 YOLOv8s，mAP0.5 和 mAP0.5:0.95 分别提升了 0.8%和 1.3%；在螺栓松动缺陷检测中查准率达到了 93.1%，查全率达到了 100%，在本巡检场景任务下优于其他算法，能够满足动车组巡检任务需求。

参考文献

[1] 杨培盛, 王华军, 张用, 等. 一种基于深度学习的地铁车体螺栓松动检测方法[J]. 轨道交通装备与技术, 2021

[2] Sun J, Xie Y, Cheng X. A fast bolt-loosening detection method of running train’s key components based on binocular vision[J]. IEEE Access, 2019, 7: 32227-32239

[3] 杨绿溪, 廖如天, 王驭扬, 张旭帆, 邓亭强. 基于深度学习和霍夫变换的六边形螺栓松动检测方法[P]. 江苏省：CN110097536A, 2019-08-06

[4] Gong H, Deng X, Liu J, et al. Quantitative loosening detection of threaded fasteners using vision-based deep learning and geometric imaging theory[J]. Automation in Construction, 2022, 133: 104009

[5] Deng X, Liu J, Gong H, et al. Detection of loosening angle for mark bolted joints with computer vision and geometric imaging[J]. Automation in Construction, 2022, 142: 104517

[6] 卢海林,冯其波,徐昌源.基于点云处理的机车车辆车底中心鞘螺栓故障检测方法[J]. 铁道机车车辆，2022,42(5):67-73

[7] R. Girshick, J. Donahue, T. Darrell, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]. in Proceedings of the IEEE conference on computer vision and pattern recognition. 2014

[8] R. Girshick. Fast r-cnn[C]. in Proceedings of the IEEE international conference on computer vision. 2015

[9] S. Ren, K. He, R. Girshick, et al. Faster r-cnn: Towards real-time object detection with region proposal networks[J]. Advances in neural information processing systems, 2015, 28

[10] Redmon J, Divvala S, Girshick R, et al. You only look once: Unified, real-time object detection[C] // Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 779-788.

[11] Liu W, Anguelov D, Erhan D, et al. Ssd: Single shot multibox detector[C]//Computer Vision–ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part I 14. Springer International Publishing, 2016: 21-37.

[12] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[C]//Proceedings of the IEEE international conference on computer vision. 2017: 2980-2988.

[13] Hou Q, Zhou D, Feng J. Coordinate attention for efficient mobile network design[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2021: 13713-13722