

深度学习驱动的桥梁支座病害检测与评估综述

姚俊宇¹, 翟志豪², 王城泉^{1,2*}, 王新泉¹, 董腾方³, 王战胜⁴, 杜亮⁴

¹浙大城市学院工程学院, 浙江杭州, 中国

²桂林理工大学土木工程学院, 广西桂林, 中国

³浙江大学建筑工程学院, 浙江杭州, 中国

⁴中交第三公路工程局有限公司, 北京, 中国

*通讯作者

【摘要】围绕桥梁支座病害智能检测与损伤评估, 本文梳理支座类型、病害机理及人工检查、无损检测、振动监测和计算机视觉方法, 重点比较 YOLO 目标检测、U-Net 图像分割、剪切角量化及无人机/机器人取像研究。对 13 项代表性研究的统计表明, 现有成果以病害定位和分类为主, 几何量化与功能状态验证相对不足。深度学习适合支座定位和多病害初筛, 但跨桥泛化、少数类召回率和角度误差更能反映工程可用性。后续应将图像结果与人工量测、振动、位移和应力信息结合, 形成“识别—量化—复核”的损伤评估流程。

【关键词】桥梁支座; 病害检测; 深度学习; 图像分割; 损伤评估

【基金项目】浙江省自然科学基金项目(编号: LTGG23E080001); 浙大城市学院 2026 年大学生创新训练计划项目(编号: X202601075)

1.引言

桥梁支座位于梁体和墩台之间, 主要作用是把上部结构荷载传给下部结构, 同时允许梁体因温度、车辆荷载和地震产生一定的位移与转角。支座体积不大, 却会直接改变桥梁的受力边界。支座一旦出现脱空、错位、过大剪切变形或转动受阻, 梁端和墩台就可能产生新的附加受力。因此, 支座检查不能只看外观是否整洁, 还要判断它是否仍能正常承压、滑移和转动[1]。

目前支座检查仍以人工近距离观察、尺量和拍照为主。此类方法直观, 但桥下空间狭窄、光照不足, 检查结果也容易受人员经验和拍摄角度影响。计算机视觉和深度学习可以帮助检查人员快速筛选大量照片, 找出

疑似开裂、脱空、外鼓和剪切变形的支座; 振动、位移和应力监测则可以补充图像看不到的功能信息[2-4]。智能检测的作用应当是提高发现问题和整理数据的效率, 而不是直接代替工程人员做出维修结论。

基于桥梁支座从病害发现到维修处置的实际流程, 本文按照“支座类型与病害—检测方法—深度学习识别—损伤评估”的主线展开。除整理相关检测与识别方法外, 还讨论检测结果如何为现场复检、病害分级和养护决策提供依据, 以加强智能检测与桥梁养护之间的联系。

2.桥梁支座的类型与病害机理

2.1 主要类型与基本功能

表 1.桥梁支座类型、主要功能与常见病害

支座类型	主要作用	常见病害	检查重点	适合的智能任务
板式/叠层橡胶支座	承压、剪切、适应转角	开裂、外鼓、脱空、剪切变形、钢板外露	支座轮廓、上下边线、接触长度	多病害检测、分割和剪切角量化
盆式/球型支座	承压、转动和滑移	锈蚀、滑板磨损、倾斜、卡滞、螺栓缺失	钢构件位置、滑移量、螺栓和滑动面	构件定位、多标签分类和位移测量
摇轴/辊轴钢支座	转动和纵向移动	锈蚀、偏位、倾覆、滚动受阻	轴线、倾角、间隙和移动轨迹	关键点检测和姿态估计
垫石及连接部位	支承、锚固和传力	垫石开裂、锚栓松失、接触不良	垫石表面、锚栓数量和密贴状态	目标检测和分割

注: 病害名称依据现行养护规范和支座检查资料归并[1]。

常见桥梁支座包括板式或叠层橡胶支 座、盆式支座、球型支座以及摇轴、辊轴等

钢支座。按约束特点又可分为固定支座和活动支座。橡胶支座依靠橡胶层的压缩和剪切变形工作，构造较简单、应用范围广；盆式和球型支座承载力较大，并利用滑动面和转动面适应梁体变位；钢支座的转轴、辊轴和连接件对锈蚀、错位较为敏感。识别病害前必须先分清支座类型，否则同一外观现象可能被错误解释。

上述支座类型的主要功能与常见病害汇总如表 1 所示。

2.2 常见病害及成因



(a) 滑移与错位



(b) 层间外鼓



(c) 脱层及钢板外露



(d) 压溃与挤出

图 1.在役橡胶支座典型病害实拍（引自文献[5]）

2.3 表观病害与功能问题的联系

表面开裂、锈蚀和垃圾堆积可以直接从照片中看到；剪切角、错位量和脱空比例需要从轮廓或边线进一步测量；承压是否均匀、滑移是否受阻以及刚度是否下降，则需要结合位移、振动、应力或现场试验判断。三类信息之间有关联，但不能简单画等号。例如，轻微龟裂不一定已经造成明显承载功能下降，而脱空虽然纹理不明显，却可能导致局部受力集中。后续智能检测应先说明自己输出的是“病害类别”“几何量”还是“功能状态”。

3.支座病害检测方法综述

3.1 人工检查与几何测量

目视检查是最基本的方法，检查人员根据支座类型查看开裂、外鼓、锈蚀、滑移、锚固和垫石状态，并通过钢尺、塞尺、位移标尺或全站仪测量间隙、位移和转角。它的

橡胶支座常见病害包括龟裂、开裂、层间外鼓、脱空、错位、剪切变形过大和加劲钢板外露；钢支座则常见锈蚀、螺栓或销钉损伤、滑动面磨损以及转动困难。病害成因通常不是单一因素：重载和反复荷载会加快材料疲劳，温度和水分会影响橡胶与钢件性能，安装偏差会造成支承面受力不均，长期缺少清理和养护又会使小问题逐步发展[1，5]。图 1 给出了在役橡胶支座的真实病害形态。

优点是能够结合桥型、温度和维修历史作出现场判断，缺点是检查频率低、不同人员的记录尺度不一致。为了让后续算法结果可以复核，现场照片应同时记录桥梁名称、支座编号、拍摄方向、日期、温度和尺度参照[1]。

3.2 无损检测与振动监测

面对目视难以触及的内部损伤或功能退化问题，工程中常引入应力波、红外热像、声发射及冲击振动等辅助检测手段。其中，应力波方法通过波速和能量衰减判别介质连续性，红外热像用于识别表面温度场异常，声发射技术可实时捕捉裂纹活动产生的瞬时信号，而振动分析则利用梁体响应或柔度变化来推断支承边界条件的改变。这些技术虽能弥补肉眼观察的不足，但其可靠性很大程度上依赖于环境温度、交通荷载、传感器布置方案及基准数据的准确性，因此目前多用

于对可疑支座的专项复核，尚不宜取代以视觉排查为主的日常养护巡查[3，4，6，7]。各类检测方法的特点与适用范围如表 2 所示。

表 2.支座检测方法的特点与适用范围

方法	主要输入	主要输出	局限	适用场景
目视与尺量	现场观察、照片、量尺	病害记录、位移和角度	主观性强、效率较低	常规巡检和验收
应力波/超声	波形、波速和幅值	内部异常位置	耦合和边界条件敏感	专项复检
红外/声发射	温度场或瞬态声信号	温度异常或裂纹活动	受环境噪声影响	疑似病害辅助判断
振动/冲击	加速度、位移、柔度	刚度变化和异常位置	需要健康基线和环境补偿	功能性检测
计算机视觉	RGB 图像或视频	类别、病害框、掩膜和几何量	只能看到可见病害	高频初筛和定量量测

3.3 应力与连续监测

对新建桥梁或计划更换的关键支座，可在支承界面布置压力、位移或应变传感器。Cao 等开发了多通道支座界面应力采集系统，在轴压和偏压试验中记录不同测点的受力变化，传感器校准精度约为±1.6%，采集板

检测误差小于 200 μV[8]。这类系统物理意义清楚，但设备成本、长期耐久和存量桥梁安装空间需要提前考虑。
该系统的构成与传感器布置如图 2 所示。




图 2.支座界面应力监测系统及轴压/偏压传感器布置（引自文献[8]，CC BY 4.0）

4.基于深度学习的支座病害智能识别

4.1 目标检测模型

目标检测适合处理一张照片中同时出现多种病害的情况。Cui 等通过位置先验和迁移学习改善小样本支座状态分类[9,10]；Gao 等针对开裂、剪切变形和脱空改进 YOLOv4[11]；Wang 和 Su 采用先定位钢支座、再分类状态的两阶段方法[12]。鲁德文和李晰建立包含 6787 张图像、7 类表观病害的 BD 数据集，对 YOLOv3、YOLOv4 和

YOLOR 进行对比，结果表明 YOLOR 在整体召回率和 mAP 方面更高[13]。这些研究说明 YOLO 类模型适合现场快速初筛，但不同论文的数据集和划分方式不同，指标不能直接横向排名。
以鲁德文和李晰[13]的研究为例，其样本、数据分布及模型检测对照如图 3 所示，YOLOv3、YOLOv4 与 YOLOR 的整体性能对比如图 4 所示。




图 3.板式橡胶支座病害样本、数据分布及模型检测对照（摘编自文献[13]）




图 4.YOLOv3、YOLOv4 与 YOLOR 整体性能对比（据文献[13]数据重绘）

4.2 图像分割与剪切角量化

只给出“存在剪切变形”还不够，工程上更关心变形有多大。对于板式橡胶支座，可以先分割支座主体，再提取轮廓并拟合上下边线。工程现场可用水平相对位移 Δ 与橡胶

层总厚度 t_e 计算剪切角，也可以用图像中两条拟合边线斜率 k_1 、 k_2 计算夹角[14]。两种方法使用的基准不同，拍照时应尽量保持正视，并进行透视校正。剪切变形与图像量测之间的几何关系如图 5 所示。



图 5.板式橡胶支座剪切变形与图像量测关系（据文献[14]整理重绘）

$$\tan \alpha = \frac{\Delta}{t_e} \tag{1}$$

$$\tan \theta = \left| \frac{k_1 - k_2}{1 + k_1 k_2} \right| \tag{2}$$

式中： α 为根据实际位移计算的剪切角， θ 为根据图像边线计算的夹角。梁栋等在 U-Net 基础上加入深度可分离卷积和多尺度注意

力模块，分割 F1 和 IoU 均超过 95%，实桥图像剪切角与人工测量的最大误差为 1.3° [14]。该研究的价值不只是模型精度高，更重要的是给出了可以人工复核的角度结果。融合深度可分离卷积与多尺度注意力的改进 U-Net 结构如图 6 所示。




图 6.融合深度可分离卷积与多尺度注意力的改进 U-Net（摘编自文献[14]）

4.3 数据集与评价指标

支座照片往往由一次检查连续拍摄，同一支座的相邻照片背景和角度很相似。如果随机按图片划分训练集和测试集，同一支座可能同时出现在两边，结果会被高估。更稳妥的做法是按桥梁或支座编号划分，并保留一座未参加训练的桥梁作为最终测试。类别不平衡也需要单独处理，严重脱空、深裂缝等少数类应重点报告召回率，而不能只看总体准确率。

$$IoU(A, B) = \frac{|A \cap B|}{|A \cup B|} \tag{3}$$

$$P = \frac{TP}{TP + FP}, R = \frac{TP}{TP + FN}, F_1 = \frac{2PR}{P + R} \tag{4}$$

检测任务应报告各类 Precision、Recall、AP 和 mAP；分割任务还应报告 IoU、Dice/F1 和边界误差；剪切角量化则应报告角度平均误差和最大误差。图像指标用于评价模型，角度、长度和分级一致率用于评价工程可用性，两类指标缺一不可。

表 3 汇总了 13 项代表性研究在研究对象、方法、数据规模、性能指标与特点局限上的对比。

表 3.代表性支座智能检测研究比较

文献（作者，年份）	研究对象/数据	方法/模型	数据规模	主要性能指标	特点与局限
Cui 等[9]（2021）	橡胶支座图像	几何注意力正则化 CNN	小规模	改善小样本状态分类	先定位后分类思路
Cui 等[10]（2022）	弹性支座	深度学习条件评估	小样本	状态评估精度提升	标签较粗
Gao 等[11]（2023）	开裂/剪切/脱空	改进 YOLOv4	未说明	三类病害可定位	场景范围有限
Wang 和 Su[12]（2023）	钢支座	BearDet+BearCla 两阶段	未说明	R=91.4%，AP=81.7%	前级漏检会传递
梁栋等[14]（2023）	天津实桥橡胶支座	改进 U-Net+边线拟合	实桥图像	F1/IoU>95%；最大角度误差 1.3°	依赖正视图与清晰边界
Liang 等[15]（2024）	工程图像	LSK-YOLOv8n	自建	mAP0.5 较基线+5.7 个百分点	缺少公共数据集
鲁德文和李晰[13]（2025）	板式橡胶支座	YOLOv3/4 与 YOLOR	6787 张，7 类	YOLOR 整体 R 与 mAP 较高	需增加跨桥测试

Fayyadh 等[6] (2012)	弹性支承	振动数据评估	试验	支承状态识别	需健康基线 与环境补偿
Chen 等[7] (2016)	梁体模态	RBF 神经网络	模态数据	支座损伤识别	依赖基准模 态
Cao 等[8] (2023)	支座界面	多通道应力采集	轴压/偏压 试验	校准精度 $\pm 1.6\%$	设备成本与 耐久受限
Zhang 等[16] (2024)	橡胶支座	CNN+有限元	试验/有限 元	损伤区域识别	依赖材料模 型与边界
Zhang 等[17] (2021)	支座桥梁	ANN 本构模型	循环试验	地震响应快速计算	依赖边界条 件
Orfeo 等[18] (2023)	自感知橡 胶	电阻量测	双剪/压缩 试验	变形自感知	仍处研究试 验阶段

表 4.基于上述 13 项研究的智能检测方法分布统计

方法类别	文献数（占比）	代表文献
目标检测（YOLO 系列/两阶段）	4（31%）	[11][12][15][13]
图像分割（U-Net）	1（8%）	[14]
CNN 分类与注意力机制	2（15%）	[9][10]
振动/响应识别	2（15%）	[6][7]
有限元/试验验证	2（15%）	[16][17]
自感知材料	1（8%）	[18]
界面应力采集	1（8%）	[8]

由表 3 可见，13 项代表性研究覆盖橡胶支座、钢支座、支座界面与自感知材料等多类对象，但数据基础差异显著：规模最大的为鲁德文和李晰[13]的 6787 张、7 类板式橡胶支座图像，最小者为小样本或试验/模态数据；仅梁栋等[14]与鲁德文和李晰[13]使用了实桥或现场图像，多数工作依赖试验或自建小样本，缺少跨桥泛化数据。在指标报告上，目标检测类多给出 mAP、Recall 或 AP（如 Wang 和 Su[12] 的 $R=91.4\%$ 、 $AP=81.7\%$ ，Liang 等[15]的 mAP0.5 较基线提高 5.7 个百分点，鲁德文和李晰[13]的 YOLOR 整体表现更优），分割类给出 F1 与 IoU；但 Gao 等[11]未说明数据规模与具体指标，Cui 等[10]标签较粗，故表中结果不应用于直接排名。从“识别—量化—验证”的链条看，多数研究停留在病害定位或分类，进入几何量化（梁栋等[14]的剪切角）或功能验证（振动[6, 7]、应力[8]、有限元[16, 17]、自感知[18]）的较少，说明从“看得见的病害”走向“可量化的损伤程度”仍是薄弱环节。表 4 进一步给出上述 13 项研究在方法类别上的分布统计。

由表 4 可见，在 13 项研究中，目标检测是绝对主力（4 项，31%），图像分割仅有 1 项（8%），几何量化相关研究明显不足。CNN 分类与注意力机制有 2 项（15%）。若

将目光转向功能状态评估类方法，合计 6 项（46%），其中振动/响应识别、有限元/试验验证各 2 项，自感知材料与界面应力采集各 1 项，说明研究者已不再满足于单纯依靠视觉信息，开始尝试将结构响应纳入评估框架，但这些探索尚处初期、彼此独立。总体上看，图像识别类占 7 项（54%），结构响应与材料验证类占 6 项（46%），后者多局限于试验验证，与前者未形成有效融合，也无统一基准可供对比。

4.4 无人机、机器人与现场应用

无人机和小型机器人能够减少人员进入梁底危险空间的次数。Peel 等研究了用于支座检查的小型移动机器人定位方法[19]；无人机桥检综述则指出，飞行平台虽然取像快，但梁底气流、遮挡、定位和安全规定都会影响应用[20]。对支座而言，设备选择应服从检测目标：拍摄裂缝需要高分辨率近景，计算剪切角需要接近正视且带尺度参照。平台负责稳定取像，深度学习负责初筛，最终仍由人工确认。

5.从病害识别到损伤评估

5.1 病害程度分级

智能评估可以分成三步。第一步识别支座类型和病害位置；第二步量化剪切角、脱空比例、裂缝面积或位移；第三步结合温度、构造类型、规范要求和历史变化提出复

检或更换建议。这样做比直接让模型输出“轻度、重度”更容易检查。系统应保留原图、支座编号、测量结果、置信度和人工修改记录,避免算法结论脱离现场。

5.2 振动与响应信息辅助判断

图像只能看到表面。Fayyadh 和 Abdul Razak 利用振动数据评估弹性支承状态[6]; Chen 等把梁体模态信息输入径向基函数神经网络,用于识别支座损伤[7]。这类方法可以发现支承刚度变化,但环境温度、车辆荷载和传感噪声也会改变响应。因此,更合理的用法是先由视觉发现疑似问题,再用振动、位移或应力进行复核。

5.3 地震损伤评估

严重地震损伤难以从在役桥梁中大量收集,试验和有限元分析可以补充训练样本。Zhang 等用橡胶支座试验校准有限元模型,再用卷积网络识别应力场中的损伤区域[16];另一项研究用循环试验数据训练神经网络本构模型,用于快速计算支座桥梁的地震响应[17]。这些方法适合科研和极端工况分析,但结果依赖材料模型与边界条件,不能直接代替现场检测。

5.4 智能检测系统的集成

一个面向实际应用的智能检测系统,不能只靠一个识别模型撑起来。除了病害检测算法,还应配套图像质量筛选、支座编号与位置管理、人工复核界面以及检测报告生成等模块,才能构成完整的工作流。对于重要桥梁或关键支座,还可在此基础上接入压力垫、位移计甚至自感知橡胶等传感元件。例如 Orfeo 等[18]通过双剪和压缩试验发现,导电橡胶的电阻变化与其变形之间存在对应关系,说明材料本身就有潜力充当传感单元。不过这类自感知支座目前仍处于实验室探索阶段,距离工程推广还有不小距离,更适合作为长期跟踪的研究方向。此外,Grad-CAM 这类可视化工具可以帮助技术人员判断模型在识别时是否聚焦于支座本身的病害区域,但热力图只是辅助理解模型的工具,不能替代工程上的合理解释与现场判断[21]。

6. 结论与展望

6.1 结论

基于文本代表性研究的对比分析,得出以下主要判断。

(1) 支座病害的诊断应区分三个信息层次:外观损伤可直接判读,剪切角与脱空率需经图像量测,功能退化则依赖位移、振动

或应力数据。三者各有用处,不能混用,工程结论应明确标注信息来源的层次。

(2) 目标检测是当前主流,而图像分割仅 1 项,几何量化研究明显不足。涉及功能状态判断的振动/响应、有限元、自感知等方向合计 6 项,说明评估思路正从纯视觉向“视觉+响应”融合的方向发展,但各方向只有零星工作,远未形成体系。就工程可用性而言,跨桥推广能力和少数病害的召回率,比 mAP 这样的单值指标更有参考价值;而分割模型输出的剪切角,也需要经人工量测和规范要求核实才能使用。

(3) 智能检测的角色应当定位于辅助筛查和养护排序的数据支撑,不能替代现场复核、施工设计和工程人员的最终判断。

6.2 未来展望

面向未来,可按三阶段推进:近期先统一开裂、脱空、剪切变形等病害名称与分级,建立按桥梁或支座编号划分、含跨桥测试的数据集,并以现场尺量结果校核剪切角与脱空比例;中期将图像与温度、位移、振动或压力数据融合,在视觉初筛后对支座功能进行复核,并用缩尺试验与有限元分析校核顶升控制参数;长期在新建或更换支座中采用便于拆换的构造与预留传感接口,使支座状态可连续记录,逐步形成检测—评估—更换—复核相衔接的养护系统。无论阶段如何,智能系统都应保留人工复核与不确定性提示,不应将低置信度结果直接转为维修结论。

参考文献

- [1] ARIA M, AKBARI R. Inspection, condition evaluation and replacement of elastomeric bearings in road bridges [J]. *Structure and Infrastructure Engineering*, 2013, 9(9): 918-934. DOI:10.1080/15732479.2011.638171.
- [2] DONG C Z, CATBAS F N. A review of computer vision-based structural health monitoring at local and global levels [J]. *Structural Health Monitoring*, 2021, 20(2): 692-743. DOI: 10.1177/1475921720935585.
- [3] LUO K, KONG X, ZHANG J, et al. Computer Vision-Based Bridge Inspection and Monitoring: A Review [J]. *Sensors*, 2023, 23(18): 7863. DOI: 10.3390/s23187863.
- [4] RIBEIRO D, RAKOCZY A M, CABRAL R, et al. Methodologies for Remote Bridge Inspection—Review [J]. *Sensors*, 2025,

- 25(18): 5708. DOI: 10.3390/s25185708.
- [5] FU C C, ANGELILLI C. Investigation of the Performance of Elastomeric Bearings on Maryland Concrete Bridges[R]. Baltimore: Maryland State Highway Administration, 2007. Report No. MD-07-SP608B4L.
- [6] FAYYADH M M, ABDUL RAZAK H. Condition assessment of elastic bearing supports using vibration data [J]. Construction and Building Materials, 2012, 30: 616-628. DOI:10.1016/j.conbuildmat.2011.12.043.
- [7] CHEN Z, FANG H, KE X, et al. A new method to identify bridge bearing damage based on Radial Basis Function Neural Network [J]. Earthquakes and Structures, 2016, 11(5): 841-859. DOI:10.12989/eas.2016.11.5.841.
- [8] CAO X, LI G, LI Z, et al. High precision and real-time acquisition system for interface stress measurement in bridge bearing [J]. Scientific Reports, 2023, 13: 1607. DOI: 10.1038/s41598-023-28848-x.
- [9] CUI M, WU G, CHEN Z Q, et al. Geometric Attention Regularization Enhancing Convolutional Neural Networks for Bridge Rubber Bearing Damage Assessment [J]. Journal of Performance of Constructed Facilities, 2021, 35(5): 04021061. DOI: 10.1061/(ASCE)CF.1943-5509.0001634.
- [10] CUI M, WU G, DANG J, et al. Deep learning-based condition assessment for bridge elastomeric bearings [J]. Journal of Civil Structural Health Monitoring, 2022, 12(2): 245-261. DOI: 10.1007/s13349-021-00540-6.
- [11] GAO X, REN H, LIU R, et al. Study on deterioration identification method of rubber bearings for bridges based on YOLOv4 deep learning algorithm[J]. Bridge Structures, 2023, 19(4): 175-188. DOI: 10.3233/BR-230209.
- [12] WANG W, SU C. Deep learning-based detection and condition classification of bridge steel bearings [J]. Automation in Construction, 2023, 156: 105085. DOI:10.1016/j.autcon.2023.105085.
- [13] 鲁德文, 李晰. 基于 YOLO 的板式橡胶支座多表观病害检测方法对比研究[J]. 青岛理工大学学报, 2025, 46 (3) : 1-8.
- [14] 梁栋, 张少杰, 周印霄等. 基于图像处理的桥梁橡胶支座剪切病害检测方法[J]. 北京交通大学学报, 2023, 47 (5) : 16-24. DOI:10.11860/j.issn.1673-0291.20230067.
- [15] LIANG D, ZHANG S, HUANG H B, et al. Deep learning-based detection and condition classification of bridge elastomeric bearings[J]. Automation in Construction, 2024, 166: 105680. DOI:10.1016/j.autcon.2024.105680.
- [16] ZHANG B, LU G, YANG C, et al. Seismic damage assessment of bonded versus unbonded laminated rubber bearings: A deep learning perspective [J]. Engineering Structures, 2024, 321: 118996. DOI:10.1016/j.engstruct.2024.118996.
- [17] ZHANG B, WANG K, LU G, et al. Seismic Response Analysis and Evaluation of Laminated Rubber Bearing Supported Bridge Based on the Artificial Neural Network [J]. Shock and Vibration, 2021: 5566874. DOI:10.1155/2021/5566874.
- [18] ORFEO A, TUBALDI E, MCALORUM J, et al. Self-Sensing Rubber for Bridge Bearing Monitoring [J]. Sensors, 2023, 23(6): 3150. DOI: 10.3390/s23063150.
- [19] PEEL H, LUO S, COHN A G, et al. Localisation of a mobile robot for bridge bearing inspection [J]. Automation in Construction, 2018, 94: 244-256. DOI:10.1016/j.autcon.2018.07.003.
- [20] JEONG E, SEO J, WACKER J. Literature Review and Technical Survey on Bridge Inspection Using Unmanned Aerial Vehicles [J]. Journal of Performance of Constructed Facilities, 2020, 34(6): 04020113. DOI: 10.1061/(ASCE)CF.1943-5509.0001519.
- [21] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization[C]//2017 IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 618-626. DOI:10.1109/ICCV.2017.74.