工程材料与结构
Engineering Materials and Structures
2026 年第 05 卷第 03 期
Vol. 05, No. 03, 2026

综　述　　http://www.scifootprint.com/EMS/index.html

深度学习在混凝土裂缝图像识别与表面损伤评估中的应用研究综述

齐孟龙

（大连理工大学建设工程学院，大连 116024）

摘要：混凝土表面裂缝的形态与演化可反映材料劣化和结构受力状态，是桥梁、隧道、路面及建筑围护结构检测中的重要指标。近年来，深度学习方法逐渐被用于裂缝图像分类、目标检测、语义分割、实例分割和几何量化，为非接触检测和数字化运维提供了新的技术路径。本文围绕图像驱动的混凝土裂缝识别与表面损伤评估，重点梳理卷积神经网络（CNN）、迁移学习、单阶段目标检测模型、快速区域卷积神经网络（Faster R-CNN）、掩膜区域卷积神经网络（Mask R-CNN）、U-Net、DeepLab、Transformer、半监督学习和基础模型在不同任务中的适用性。研究表明，分类模型适用于快速筛查，目标检测模型侧重裂缝定位，像素级分割更有利于形态提取和损伤量化。当前研究正由图像级识别向精细定位和像素级提取发展，但真实几何参数测量及损伤评估仍不充分。数据集代表性、标注成本、跨场景泛化、尺度标定和工程验证是制约实际应用的主要因素。未来应加强轻量化部署、标注高效学习、多模态测量及工程验证，推动裂缝识别向损伤量化与养护决策支持发展。

关键词：混凝土裂缝；深度学习；图像识别；损伤评估；结构健康监测

DOI：10.48014/ems.20260722001

引用格式：齐孟龙．深度学习在混凝土裂缝图像识别与表面损伤评估中的应用研究综述[J]．工程材料与结构，2026，5(3)：127-139.

1　引言

混凝土结构在服役过程中会受到荷载循环、温湿度变化、收缩徐变、冻融循环、氯盐侵蚀、碳化以及施工质量差异等因素影响。裂缝通常首先出现在结构表面，并通过改变渗透路径、加快水分和腐蚀性介质进入、削弱保护层完整性等方式影响耐久性。早期裂缝并不总是意味着结构承载能力立即失效，但其空间分布、宽度、长度、连通性和发展速率往往包含了材料劣化和结构受力状态的重要信息。因此，裂缝识别不仅是外观病害记录问题，也是耐久性评估、维修决策和寿命管理中的基础环节[1-6]。

传统巡检主要依赖人工目测、裂缝尺、照相记录和经验判断。这类方法具有直观、成本低和便于现场实施的优点，但当检测对象扩展到长大桥梁、隧道群、城市道路网络和高层建筑外立面时，人工方法会受到效率、主观一致性、安全风险和数据归档标准化的制约。20 世纪末至 21 世纪初，阈值分割、边缘检测、形态学处理和纹理特征等传统计算机视觉方法开始用于裂缝识别[2,4]。这些方法在背景较简单、光照稳定的图像上能够取得可解释的结果，但其特征设计依赖人工经验，对阴影、接缝、污渍、粗糙骨料纹理、低对比度和尺度变化较为敏感[5,7,8]。

深度学习改变了裂缝图像分析的建模方式。

通讯作者　Corresponding author：齐孟龙，menglongqi@outlook.com

收稿日期：2026-07-22；　**录用日期**：2026-07-24；　**发表日期**：2026-09-28

卷积神经网络能够从样本中学习裂缝边缘、纹理和形态特征；全卷积网络、U-Net 和 DeepLab 等结构使裂缝识别从图像级分类扩展到像素级分割；YOLO、Faster R-CNN 和 Mask R-CNN 使裂缝及相关表面病害能够被快速定位；Transformer、状态空间模型、半监督学习和基础模型则进一步针对长程依赖、复杂背景和标注不足等问题展开探索[1,3,9-18]。在工程应用层面，无人机、车载相机、隧道巡检机器人和移动端设备的普及，也为裂缝图像数据持续采集提供了条件。

现有研究已证明深度学习具有较强的自动特征提取能力，但仍存在一个尚未充分解决的知识空缺[1,3,6]：许多模型在单一公开数据集或随机划分测试集上表现良好，却难以说明其在不同结构类型、不同成像设备、不同气候和不同损伤等级下的稳定性；同时，裂缝检测结果如何转化为宽度、长度、密度、贯通性和维修优先级等工程指标，仍缺乏统一流程。基于此，本文旨在以近年深度学习裂缝视觉检测研究为对象，从任务体系、技术方法、数据基础、评价指标和工程可靠性五个方面进行归纳，以明确该领域的研究进展、现存不足和后续发展方向。本文聚焦基于图像的混凝土裂缝识别与表面损伤评估，不展开讨论抗压强度预测、配合比优化等非图像类混凝土深度学习任务。

2 混凝土裂缝图像识别的基本原理与任务特征

混凝土裂缝是结构表面最常见的损伤形态之一，其视觉特征通常表现为细长、低宽度、高长宽比和边缘不规则等特点。与一般目标识别任务相比，裂缝图像识别面临更复杂的背景干扰。一方面，混凝土表面常存在骨料纹理、施工接缝、污渍、水迹、阴影和剥落等干扰因素；另一方面，裂缝本身可能呈现断续分布、局部低对比度和尺度差异明显等特征。这使得传统基于阈值分割、边缘检测和形态学处理的方法在复杂工程场景中容易出现误检和漏检[2,21,22]。

深度学习方法的优势在于能够从样本数据中自动提取多层次图像特征。浅层卷积特征通常对应边缘、纹理和灰度突变信息，深层特征则能够表达裂缝的空间形态、上下文关系和语义类别。基于这一特征学习机制，混凝土裂缝识别逐渐由传统人工特征设计转向端到端的数据驱动建模。典型流程包括图像采集、数据标注、图像预处理、模型训练、裂缝识别、结果后处理和损伤指标计算。其中，图像采集质量、标注一致性和训练集代表性直接影响模型在工程现场中的可靠性[4,5,23,24]。一种典型的识别与状态评估流程如图 1 所示，主要包括图像采集与处理、数据集划分、模型选择、训练验证、性能评价以及分类和语义分割结果输出。其中，分类用于判别缺陷类型，语义分割用于提取缺陷区域，为后续损伤量化与状态评估提供基础。

从任务层级来看，现有研究大体可分为图像分类、目标检测、语义分割、实例分割和裂缝量化五类。图像分类主要判断图像块中是否存在裂缝，具有标注成本低、模型结构相对简单的特点，但不能提供裂缝位置和几何参数[10-12]。目标检测通过边界框定位裂缝区域，适合桥梁、隧道、路面等场景的快速巡检，但矩形框难以准确描述细长裂缝的真实形态[13-17]。语义分割和实例分割能够获得像素级裂缝区域，是裂缝宽度、长度、面积和连通性计算的重要基础，但对像素级标注质量和模型边界识别能力要求更高[18,19,25]。裂缝量化则进一步将识别结果转化为工程评价指标，是从“是否识别裂缝”走向“如何评价损伤程度”的关键环节。

因此，混凝土裂缝图像识别并不是单一的计算机视觉分类问题，而是连接材料劣化表征、结构状态评估和养护决策的综合性任务。不同深度学习模型的适用性也应结合任务目标进行判断：CNN 类模型适合裂缝分类和基础特征提取，YOLO 等检测模型适合实时定位，U-Net、DeepLab 和 Mask R-CNN 等分割模型更适合几何量化，Transformer、半监督学习和自监督学习则主要面向复杂背景建模、标注成本降低和跨场景泛化等问题[1,3,20]。基于上述任务特征，后文将进一步从方法演进、数据基础、评价指标和工程应用可靠性等方面梳理近年研究进展。

3 混凝土裂缝图像识别与损伤评估研究进展

3.1 基于 CNN 的裂缝图像分类与特征提取

卷积神经网络（CNN）是裂缝视觉识别中最早

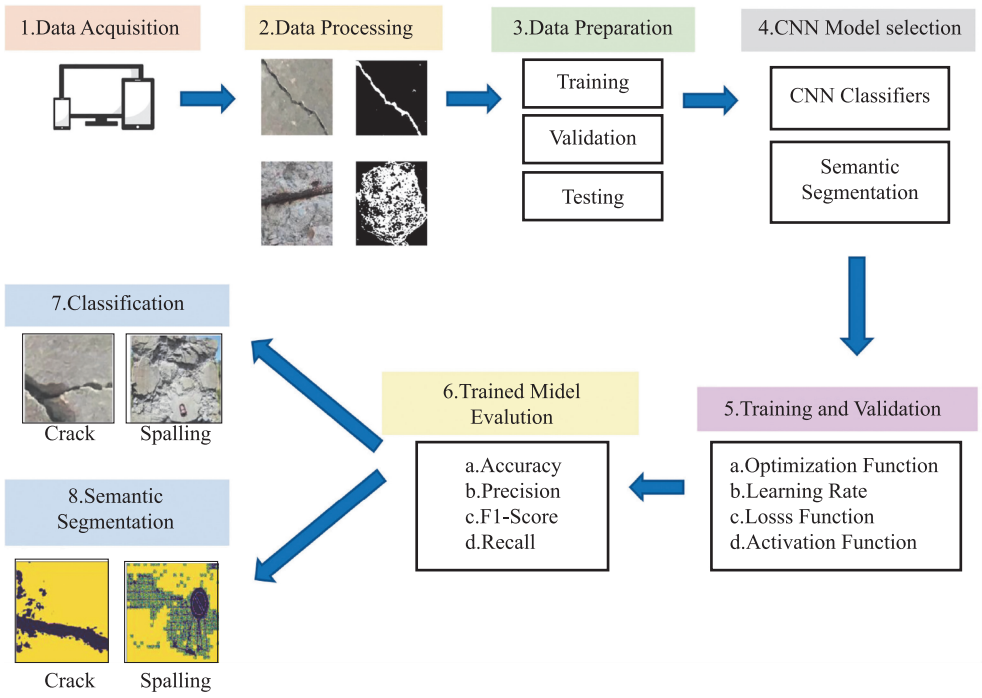

图 1　一种基于深度学习的混凝土缺陷识别与状态评估总体流程[59]

Fig. 1　Overall workflow of deep learning-based concrete defect identification and condition assessment[59]

被系统采用的深度模型之一。与传统阈值或边缘检测不同,CNN 通过卷积核在训练过程中学习局部纹理、灰度突变和边缘形态,从而减少人工设计特征的依赖。Cha 等[9]、Gopalakrishnan 等[10]和 Zhang 等[11]的早期研究表明,CNN 和迁移学习可在图像块级裂缝识别中建立稳定基线。SDNET2018 的发布进一步推动了混凝土桥面、墙体和路面裂缝图像分类研究[12]。迁移学习的意义在于,当混凝土裂缝标注样本不足时,可利用 ImageNet 等大规模视觉数据中学习到的通用边缘和纹理表示,再通过少量工程图像微调模型[26]。如图 2 所示。该流程体现了 CNN 裂缝识别由图像分类向区域定位的拓展。

不过,分类模型的输出通常停留在“有无裂缝”或“病害类别”层面。在巡检报告中,仅知道某张图像含裂缝并不足以指导维修;工程人员更关心裂缝的位置、宽度、走向和发展趋势。因此,CNN 分类更适合用作图像筛选、低成本预警和移动端初筛,而不宜直接替代裂缝量测。

3.2　基于目标检测模型的裂缝区域定位

目标检测模型使裂缝识别从图像级判断进入空间定位阶段。Faster R-CNN 和 Mask R-CNN 等两阶段方法具有较强的定位和实例表达能力,但模型复杂度较高[14,27,28]。YOLO 系列模型将候选区域生成和类别回归统一到单阶段框架中,具有推理速度快、部署便利的特点,因此在车载巡检、移动端检测和无人机图像分析中被广泛采用[13,15,29,30]。作为目标检测基础模型,YOLO 的实时检测思想也为后续裂缝和道路病害检测模型提供了重要方法基础[31]。以 BL-YOLOv8 为例,Wang 等[13]基于 BiFPN 重构 YOLOv8s 的颈部网络,并引入 SimSPPF 和 LSK-attention 模块,以增强多尺度特征融合和复杂背景下的目标表征能力,其改进结构如图 3 所示。

近年来,面向道路病害和裂缝检测的 YOLO 改进模型不断增多。例如,YOLOv8-PD、YOLOv7 和 Cycle-YOLO 等方法分别从轻量化、注意力机制、检测精度和鲁棒性等方面进行了改进[13,29,30,32]。国内研究中,李想和熊进刚[16]采用 SSD 目标检测算法识别混凝土结构裂缝,尹初等[17]则将先验信息引入级联检测过程,用于提升复杂场景下裂缝检测效果。

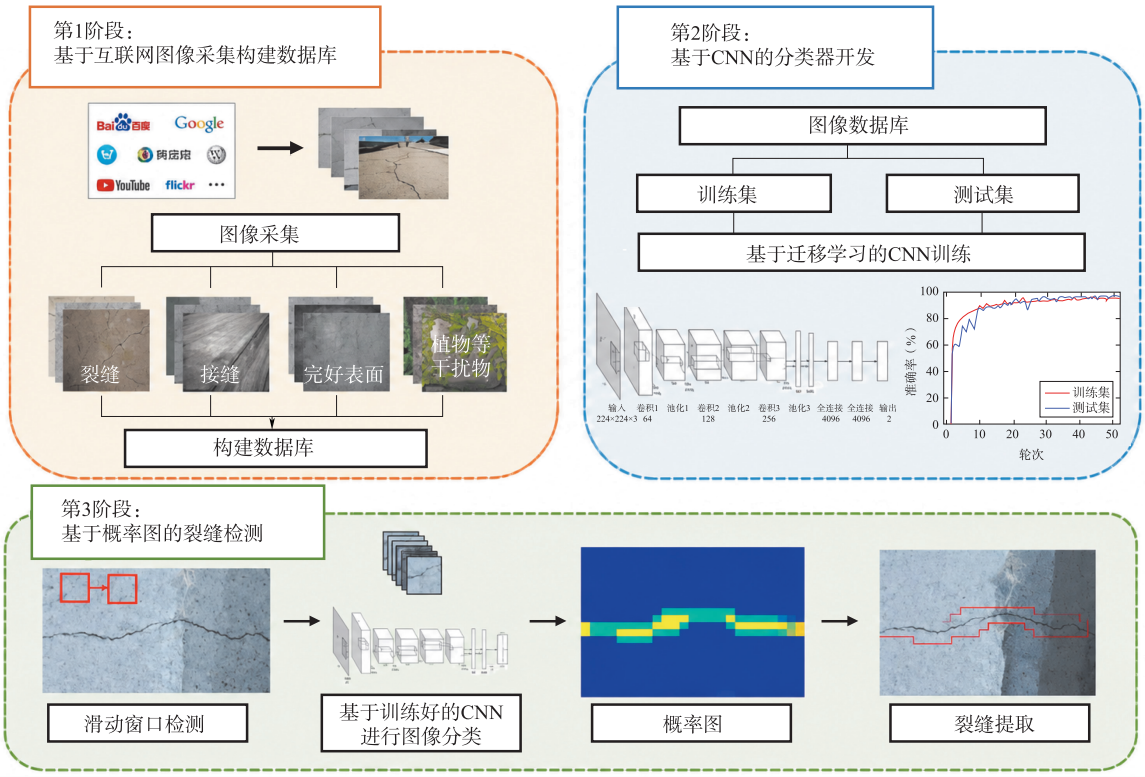

图 2　基于 CNN 的混凝土裂缝检测流程[58]

Fig. 2　Workflow of concrete crack detection based on CNN[58]

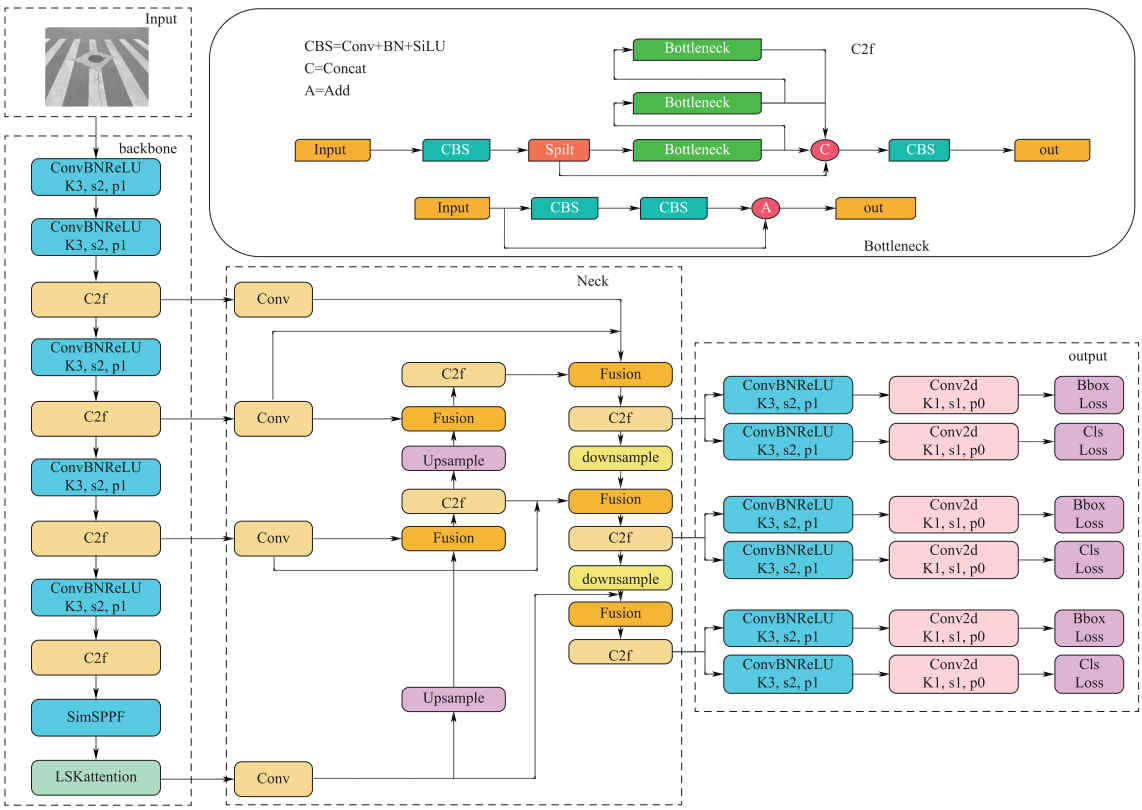

图 3　YOLOv8s 的改进结构[13]

Fig. 3　Improved structure of YOLOv8s[13]

目标检测的主要问题在于,裂缝通常是细长且弯曲的目标,边界框会把大量非裂缝背景包含在内。当研究目标是“发现裂缝位置”时,检测框具有工程价值;当目标转向“测量裂缝宽度”或“判断贯通性”时,检测框的信息密度不足。因此,目标检测更适合作为巡检系统的前端定位模块,后续仍需分割或几何量化方法完成精细评估。

3.3 基于语义分割模型的裂缝像素级识别

裂缝分割是近年来研究最集中的方向。FCN将分类网络改造为密集预测框架[33],使图像中每个像素都能够获得类别标签;U-Net通过编码-解码结构和跳跃连接融合浅层纹理与深层语义[34],被广泛迁移到裂缝分割任务[18,19];DeepLab借助空洞卷积和多尺度上下文建模处理不同宽度裂缝[35];DeepCrack则通过层级卷积特征增强裂缝边界恢复[25]。这些模型使裂缝面积、长度、宽度和连通性等指标具有进一步计算的可能。

围绕分割精度提升,研究者进一步提出CrackW-Net、多尺度注意力网络、层级特征融合网络和连接注意力结构等改进方法,以处理裂缝边界弱、形态细长和背景复杂等问题[36-38]。国内研究也针对特殊结构和细小裂缝识别提出了TCS-Net、M-Unet以及基于语义分割的路面裂缝识别方法,分别面向核电安全壳细小裂缝、混凝土裂缝实时分割和沥青路面裂缝智能识别等场景[39-41]。

实例分割在语义分割基础上进一步区分不同裂缝或不同病害实例,Mask R-CNN是其代表性方法[14,28]。对工程应用而言,实例级表达有助于将多条裂缝分开编号,并与位置、构件类型和维修记录对应。然而,裂缝边缘常呈现模糊、断续和弱对比特征,像素级标注也存在主观差异。若训练标注的边界本身不一致,模型输出的几何量化结果也会出现系统误差。

3.4 基于Transformer的复杂背景裂缝识别

2022年以来,Transformer及其变体逐渐进入裂缝识别研究。与卷积网络偏重局部邻域不同,Transformer通过自注意力机制表达长程依赖,适合处理裂缝的长条形态、断续分布和复杂背景关系。已有研究将视觉Transformer用于沥青与混凝土表面裂缝检测,也有研究将Transformer引入混凝土裂缝分割模型,以提高复杂场景下的上下文建模能力[20,42,43]。DETR类模型和混合注意力结构也进一步拓展了Transformer在缺陷检测中的应用范围[44]。

近期Vision Mamba、Swin类结构和多尺度Transformer网络进一步将研究重点推向高分辨率图像、复杂背景和计算效率之间的平衡[45,46]。在国内研究中,丁威等将负压吸附爬壁机器人与Transformer结合,用于混凝土桥塔裂缝识别检测,体现了深度学习方法与工程巡检装备融合的趋势[6]。

另一方面,像素级裂缝标注成本高,限制了大规模分割模型训练。半监督和对抗学习方法尝试利用少量标注图像与大量未标注图像共同训练[47,48];弱监督、少样本学习和自监督预训练则试图减少对人工掩膜的依赖。基础模型如SAM为提示式分割提供了新的工具,但裂缝细小、低对比和拓扑连续性要求较高,通用模型直接迁移到裂缝分割时仍需领域适配[49-51]。因此,基础模型并不意味着标注问题已经被完全解决,其价值更可能体现在交互式标注、候选掩膜生成和跨场景预训练方面。

3.5 面向损伤评估的裂缝几何量化方法

自动识别的最终目标并非得到一张“好看”的分割图,而是形成可用于养护决策的损伤信息。Park等[52]将深度学习与结构光结合,实现裂缝检测和几何量化;Fan等[53]利用CNN概率图和骨架提取进行裂缝长度、宽度测量;Deng等[54]进一步将少样本分割、SAM和LiDAR-SLAM结合,探索三维空间中的裂缝测量。此类研究表明,裂缝识别正在由“视觉分类任务”转向“工程测量任务”。

从工程应用角度看,裂缝几何量化需要考虑像素尺寸标定、拍摄距离、相机姿态、结构曲面和裂缝深度等因素。多时相巡检研究进一步表明,裂缝检测不仅需要识别单次图像中的裂缝区域,还应关注裂缝随时间变化的扩展趋势[55]。对于隧道衬砌、桥塔和核电安全壳等特殊结构,裂缝检测结果还需与结构部位、服役环境和安全等级联系起来,才能形成更可靠的损伤评估结果[5,6,39]。

图 4 以 59 篇文献为分析单元：先依据研究目标将其编码为综述/数据集、分类、目标检测、语义分割、实例分割、裂缝量化和跨场景/泛化等任务，再依据主要技术路线编码为 CNN/迁移学习、YOLO/单阶段检测、R-CNN/Mask R-CNN、U-Net/FCN/DeepLab、Transformer/DETR、半监督/弱监督、基础模型/多模态及综述/数据集等方法族。同一文献涉及多个任务或方法时允许多重编码，因而图中汇总值表示编码次数而非独立文献数；共得到 84 个任务-方法编码对，其中语义分割为 33 次（39.3%），目标检测为 18 次（21.4%），分类为 12 次（14.3%），裂缝量化仅 4 次（4.8%）。这表明研究仍主要集中于裂缝识别与边界提取，面向工程尺度量测的证据相对不足。

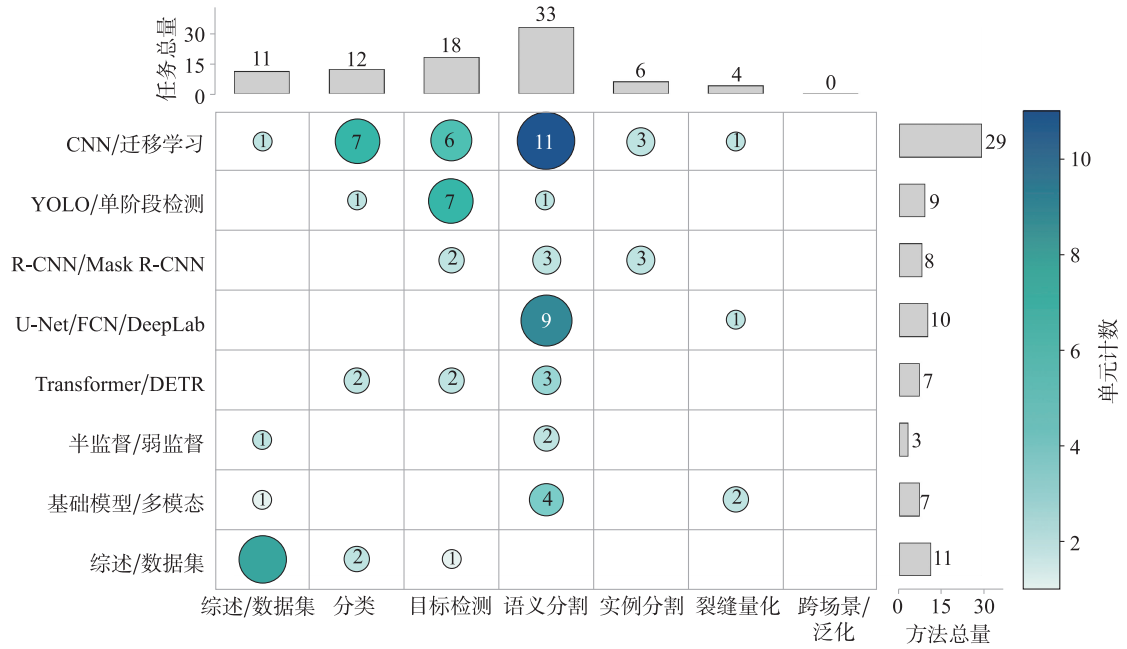

图 4　裂缝分析任务中不同方法族的证据分布

Fig. 4　Evidence distribution across method families and crack-analysis tasks

4　数据集、评价指标与可靠性

数据集是裂缝视觉模型性能的基础。SDNET2018、CFD/CrackForest、Crack500、DeepCrack、RDD 系列和各类自建桥梁/隧道/UAV 数据集在研究中被频繁使用[12,25,30,56]。其中，RDD 系列数据集推动了道路病害检测和分类模型在移动端图像中的应用[56]；DeepCrack 等数据集则常用于裂缝边界恢复和像素级分割比较[25]。这些数据集在对象、标注方式和场景复杂度上差异较大。

评价指标也应与任务目标对应。分类任务常用 Accuracy、Precision、Recall 和 F1；目标检测常用 mAP、IoU 和 FPS；语义分割常用 IoU、mIoU、Dice/F1 和 Pixel Accuracy；裂缝量化则需要报告宽度误差、长度误差、面积误差、尺度标定误差和重复测量误差[1,2,52,53]。分类准确率高并不意味着能够测量裂缝宽度，检测 mAP 较高也不能说明裂缝边界已被准确恢复。因此，面向工程应用的研究应同时报告识别指标、几何指标、推理速度和失败样例。

可靠性问题主要体现在三个方面[1,3,50]：

（1）随机划分可能使同一工程或相似纹理同时出现在训练集和测试集，导致泛化能力被高估。

（2）不同论文在图像裁剪、增强、阈值后处理和训练/测试划分上差异明显，使指标横向比较存在困难。

（3）现场部署需要考虑相机标定、光照变化、拍摄角度、推理延迟和人工复核流程。只有在跨数据集、跨工程项目和真实巡检数据上进行验证，模型结果才更接近工程可用性评价。

表 1 混凝土裂缝图像识别常用数据集及其适用任务

Table 1 Common datasets for concrete crack image recognition and their applicable tasks

数据集/来源	主要对象与场景	标注类型	适用任务
SDNET2018	混凝土桥面、墙体、路面图像	图像级裂缝/非裂缝标签	分类、迁移学习
CFD/CrackForest	路面裂缝图像	像素级或近似像素级标注	分割、边缘检测比较
Crack500	城市道路裂缝图像	像素级分割标注	语义分割
DeepCrack	多场景裂缝图像	像素级标注	层级 CNN 分割、边界恢复
RDD 系列数据集	多国家道路病害图像	边界框和病害类别	目标检测、轻量部署
自建桥梁/隧道/UAV/水工数据集	桥梁、隧道衬砌、水工结构、无人机视角	图像级、框级或像素级	检测、分割、量化、巡检报告

5 目前挑战与未来研究方向

5.1 目前挑战

图 5 采用定性内容分析结合频数统计,对 59 篇文献在结果、讨论或结论中明确指出的局限进行编码。编码类别包括跨数据集/跨场景泛化、工程现场长期验证、像素级标注、细裂缝与不均衡样本、实时部署与算力、光照与背景干扰、可复现性/公开协议以及几何量化与尺度标定。同一文献可对应多个类别。共获得 73 个挑战提及,百分比以 73 为分母。跨数据集/跨场景泛化不足出现 27 次(37.0%),工程现场长期验证不足 12 次(16.4%),其余问题均不超过 10%。当前研究不足主要集中在跨场景泛化、复杂背景干扰、标注成本、细裂缝漏检、实时部署和工程量化等方面。这些问题与裂缝目标本身的形态特征密切相关,也与数据采集和评价协议有关[1,2,50]。因此,当前瓶颈并非仅是单一模型精度,而是模型在新场景中的稳定性以及识别结果向可复核工程指标的转化能力。

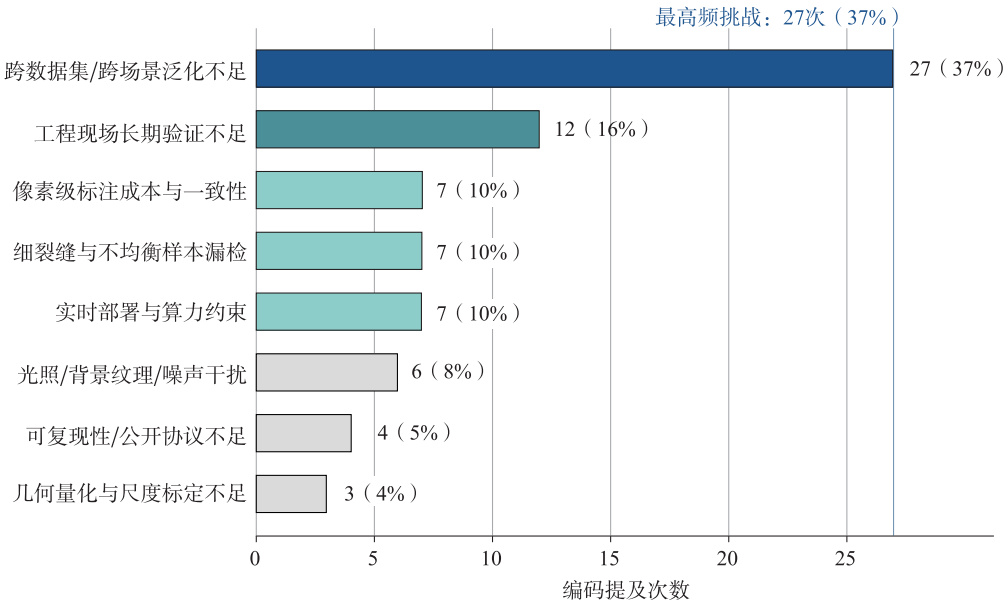

图 5 基于深度学习的裂缝分析研究挑战编码

Fig. 5 Challenge coding of deep learning-based crack analysis studies

(1)数据集代表性不足

公开数据集为模型训练和方法比较提供了基础,但多数数据来自特定地区、特定结构或特定拍摄条件,部分数据集以路面图像为主,不能充分代表桥梁、隧道、水工结构和建筑外墙等场景中的混凝土裂缝。不同结构表面的纹理、光照、污染和裂缝形态差异较大,若训练数据覆盖不足,模型容易学习到数据集特有背景特征,从而影响实际应用中

的稳定性[3-6]。

(2)像素级标注成本高且一致性不足

裂缝分割和几何量化通常需要像素级标注,但细裂缝边界模糊、断续区域和污染背景会增加标注难度。不同标注者对裂缝端部、分叉区域和疑似裂缝纹理的判断可能不一致,进而影响模型训练和评价结果。对于以 IoU、Dice 或 mIoU 为主要指标的分割任务,标注边界差异还可能导致性能评价出现偏差[39,47,48]。

(3)跨场景泛化能力不足

许多研究仍采用单一数据集内部随机划分的方式进行训练和测试,外部测试、跨相机测试和跨工程项目测试相对较少。这种评价方式可能高估模型性能。实际巡检中,模型需要面对不同设备、不同拍摄距离、不同光照条件和不同结构表面,容易出现漏检、误检或分割不连续等问题。因此,跨数据集验证和现场验证应成为后续研究的重要环节[1,3,50,55]。

(4)工程部署与损伤量化不足

模型指标通常强调 mAP、F1 或 mIoU,但维修决策更需要裂缝宽度、长度、密度、贯通性和损伤等级;此外,边缘设备推理速度、功耗、尺度标定和人工复核机制也需要纳入评价。现有研究中,YOLO 类模型和实时分割模型已尝试面向部署优化,但识别结果到工程决策之间仍需要更完整的量化流程[13,29,46,57]。

5.2 未来研究方向

针对混凝土裂缝图像识别与表面损伤评估中存在的数据集代表性不足、跨场景泛化能力有限、细小裂缝漏检、模型部署成本较高以及识别结果与工程损伤评价脱节等问题,后续研究需要从算法性能、损伤机理、应用场景和多学科融合等方面进一步深化。与早期研究主要追求分类准确率或分割精度不同,未来研究应更加关注模型在真实工程环境中的稳定性、可解释性和可用性,使深度学习方法能够从“图像识别工具”进一步发展为服务结构检测、耐久性评估和智能养护决策的技术支撑。

(1)技术优化。后续研究应在轻量化检测、高精度分割和实时部署之间建立平衡。YOLO、MobileNet、轻量 Transformer、Vision Mamba、剪枝、量化和知识蒸馏可用于降低模型复杂度;同时,应避免只压缩参数而忽视小裂缝召回率和边界连续性。

(2)机制深挖。裂缝识别需要从“图像中是否存在裂缝”扩展到“裂缝几何参数如何对应损伤状态”。未来可将裂缝宽度、长度、密度、分叉、方向和连通性与构件位置、暴露环境、渗水、锈蚀和材料劣化过程联系起来,建立视觉特征与耐久性风险之间的可解释映射。

(3)场景扩展。现有模型需要更多面向桥梁腹板、桥面铺装、隧道衬砌、港口与水工结构、海工构件和建筑外墙的验证。图像来源也不应限于 RGB 照片,还可扩展到红外热像、结构光、激光扫描、三维点云、无人机视频和多时相巡检数据[13,39,45]。

(4)学科交叉。裂缝视觉识别应与结构健康监测、材料耐久性、机器人巡检、数字孪生和智能养护平台结合。更合理的工作流不是以模型替代人工判断,而是建立“自动识别—风险排序—人工复核—维修记录—模型更新”的闭环。基础模型和多模态学习可用于降低标注门槛,但其输出必须经过工程尺度标定和误差评估。

6 结论

深度学习已推动混凝土裂缝检测由人工经验判断和传统图像处理逐渐转向数据驱动的自动识别与辅助评估。本文从任务体系、技术方法、数据基础、评价指标和工程可靠性五个方面综述了深度学习在混凝土裂缝识别与表面损伤评估中的应用,重点梳理了裂缝分类、目标检测、语义分割、实例分割和损伤量化等任务中的代表性方法及其适用场景。主要结论如下:

(1)不同方法的工程功能边界较为清晰。CNN 和迁移学习适合图像级筛查,YOLO 等检测模型适合快速定位,U-Net、DeepLab、FCN 和 Mask R-CNN 等像素级模型更有利于提取裂缝宽度、长度和面积所需的几何信息。

(2)现有研究主要集中于裂缝分类、目标检测和语义分割,而对裂缝宽度、长度及面积等几何参数的量化关注不足。研究重点仍偏向提升识别精度,由像素级结果向尺度可靠、具有工程意义的损

伤指标转化,尚缺乏成熟方法。

(3)单一数据集上的高 Accuracy、mAP 或 IoU 不能直接等同于工程可用性,仍需开展跨项目、跨设备和多时相验证。

(4)Transformer、半监督学习和基础模型有助于复杂背景建模和降低标注成本,但其泛化能力和工程可靠性仍需通过跨数据集与现场验证进一步检验。

混凝土裂缝视觉检测的研究重点正在从单一数据集性能提升,转向可泛化、可量化、可部署和可复核的工程应用体系。未来研究应更加重视数据集代表性、尺度标定、损伤指标提取、模型不确定性和人工复核机制,使深度学习方法能够更可靠地服务于混凝土结构状态评估与智能养护决策。

利益冲突:作者声明没有利益冲突。

参考文献(References)

[1] YUAN Q,SHI Y F,LI M Y. A Review of Computer Vision-Based Crack Detection Methods in Civil Infrastructure: Progress and Challenges [J]. Remote Sensing, 2024,16(16):2910.
https://doi.org/10.3390/rs16162910.

[2] KHAN M A M,KEE S H,PATHAN A K,et al. Image Processing Techniques for Concrete Crack Detection: A Scientometrics Literature Review[J]. Remote Sensing, 2023,15(9):2400.
https://doi.org/10.3390/rs15092400.

[3] AMIRKHANI D, ALLILI M S, HEBBACHE L, et al. Visual Concrete Bridge Defect Classification and Detection Using Deep Learning: A Systematic Review [J]. IEEE Transactions on Intelligent Transportation Systems,2024,25(9):10483-10505.
https://doi.org/10.1109/tits.2024.3365296.

[4] 杨杰文,章光,陈西江,等. 基于深度学习的较复杂背景下桥梁裂缝检测[J]. 铁道科学与工程学报,2020,17(11):2722-2728.
https://doi.org/10.19713/j.cnki.43-1423/u.T20200107.

[5] 王建锋,刘文豪,潘清云. 基于图像处理与深度学习的隧道衬砌裂缝检测[J]. 北京交通大学学报,2022,46(5):19-29.
https://doi.org/10.11860/j.issn.1673-0291.20210200.

[6] 丁威,夏哲,舒江鹏,等. 基于负压吸附爬壁机器人和Transformer 的混凝土桥塔裂缝识别检测[J]. 中国公路学报,2024,37(2):53-64.
https://doi.org/10.19721/j.cnki.1001-7372.2024.02.005.

[7] GOPALAKRISHNAN K. Deep Learning in Data-Driven Pavement Image Analysis and Automated Distress Detection: A Review[J]. Data,2018,3(3):28.
https://doi.org/10.3390/data3030028.

[8] 沙爱民,童峥,高杰. 基于卷积神经网络的路表病害识别与测量[J]. 中国公路学报,2018,31(1):1-10.
https://doi.org/10.19721/j.cnki.1001-7372.2018.01.001

[9] CHA Y J,CHOI W,BÜYÜKÖZTÜRK O. Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks[J]. Computer-Aided Civil and Infrastructure Engineering,2017,32(5):361-378.
https://doi.org/10.1111/mice.12263.

[10] GOPALAKRISHNAN K,KHAITAN S K,CHOUDHARY A, et al. Deep Convolutional Neural Networks with transfer learning for computer vision-based data-driven pavement distress detection [J]. Construction and Building Materials,2017,157:322-330.
https://doi.org/10.1016/j.conbuildmat.2017.09.110.

[11] ZHANG L, YANG F, ZHANG Y D, et al. Road crack detection using deep convolutional neural network [C]//2016 IEEE International Conference on Image Processing(ICIP). Piscataway: IEEE,2016:3708-3712.
https://doi.org/10.1109/ICIP.2016.7533052.

[12] DORAFSHAN S, THOMAS R J, MAGUIRE M. SDNET2018: An annotated image dataset for non-contact concrete crack detection using deep convolutional neural networks[J]. Data in Brief,2018,21:1664-1668.
https://doi.org/10.1016/j.dib.2018.11.015.

[13] WANG X Q,GAO H B,JIA Z M,et al. BL-YOLOv8: An Improved Road Defect Detection Model Based on YOLOv8[J]. Sensors,2023,23(20):8361.
https://doi.org/10.3390/s23208361.

[14] XU X Y,ZHAO M,SHI P X,et al. Crack Detection and Comparison Study Based on Faster R-CNN and Mask R-CNN[J]. Sensors,2022,22(3):1215.
https://doi.org/10.3390/s22031215.

[15] GUO G G,ZHANG Z Y. Road damage detection algorithm for improved YOLOv5[J]. Scientific Reports, 2022,12(1):15523.
https://doi.org/10.1038/s41598-022-19674-8.

[16] 李想,熊进刚. 基于深度学习 SSD 目标检测算法的混凝土结构裂缝识别[J]. 南昌大学学报(工科版),2021,

43(1):43-51.
https://doi.org/10.13764/j.cnki.ncdg.2021.01.007.

[17] 尹初,赵启林,芮挺,等.先验信息强化的混凝土裂缝深度学习级联检测算法研究[J].公路,2023,68(1):228-234.

[18] LAU S,CHONG E K P,YANG X,et al. Automated Pavement Crack Segmentation Using U-Net-Based Convolutional Neural Network[J]. IEEE Access,2020,8:114892-114899.
https://doi.org/10.1109/access.2020.3003638.

[19] ZHANG L X,SHEN J K,ZHU B J. A research on an improved Unet-based concrete crack detection algorithm[J]. Structural Health Monitoring,2021,20(4):1864-1879.
https://doi.org/10.1177/1475921720940068.

[20] WANG W J,SU C. Automatic concrete crack segmentation model based on transformer[J]. Automation in Construction,2022,139:104275.
https://doi.org/10.1016/j.autcon.2022.104275.

[21] CAO W M,LIU Q F,HE Z Q. Review of Pavement Defect Detection Methods[J]. IEEE Access,2020,8:14531-14544.
https://doi.org/10.1109/access.2020.2966881.

[22] QU Z,MEI J,LIU L,et al. Crack Detection of Concrete Pavement With Cross-Entropy Loss Function and Improved VGG16 Network Model[J]. IEEE Access,2020,8:54564-54573.
https://doi.org/10.1109/access.2020.2981561.

[23] REN Y P,HUANG J S,HONG Z Y,et al. Image-based concrete crack detection in tunnels using deep fully convolutional networks[J]. Construction and Building Materials,2020,234:117367.
https://doi.org/10.1016/j.conbuildmat.2019.117367.

[24] DUNG C V,ANH L D. Autonomous concrete crack detection using deep fully convolutional neural network[J]. Automation in Construction,2019,99:52-58.
https://doi.org/10.1016/j.autcon.2018.11.028.

[25] ZOU Q,ZHANG Z,LI Q Q,et al. DeepCrack:Learning Hierarchical Convolutional Features for Crack Detection[J]. IEEE Transactions on Image Processing,2019,28(3):1498-1512.
https://doi.org/10.1109/tip.2018.2878966.

[26] MATARNEH S,ELGHAISH F,POUR RAHIMIAN F,et al. Evaluation and optimisation of pre-trained CNN models for asphalt pavement crack detection and classification[J]. Automation in Construction,2024,160:105297.
https://doi.org/10.1016/j.autcon.2024.105297.

[27] SINGH J,SHEKHAR S. Road Damage Detection And Classification In Smartphone Captured Images Using Mask R-CNN[EB/OL]. arXiv,2018[2026-06-29]. https://arxiv.org/abs/1811.04535.

[28] HE K M,GKIOXARI G,DOLLÁR P,et al. Mask R-CNN[C]//2017 IEEE International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2017:2980-2988.
https://doi.org/10.1109/ICCV.2017.322.

[29] ZENG J Y,HAN Z. YOLOv8-PD:an improved road damage detection algorithm based on YOLOv8n model[J]. Scientific Reports,2024,14(1):12052.
https://doi.org/10.1038/s41598-024-62933-z.

[30] PHAM V,NGUYEN D,DONAN C. Road Damage Detection and Classification with YOLOv7[C]//2022 IEEE International Conference on Big Data(Big Data). Piscataway:IEEE,2022:6416-6423.
https://doi.org/10.1109/bigdata55660.2022.10020856.

[31] REDMON J,DIVVALA S,GIRSHICK R,et al. You Only Look Once:Unified,Real-Time Object Detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Piscataway:IEEE,2016:779-788.
https://doi.org/10.1109/CVPR.2016.91.

[32] LI Z J,XIAO X,XIE J C,et al. Cycle-YOLO:A Efficient and Robust Framework for Pavement Damage Detection[EB/OL]. arXiv,2024[2026-06-29]. https://arxiv.org/abs/2405.17905.

[33] LONG J,SHELHAMER E,DARRELL T. Fully convolutional networks for semantic segmentation[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2015:3431-3440.
https://doi.org/10.1109/CVPR.2015.7298965.

[34] RONNEBERGER O,FISCHER P,BROX T. U-Net:Convolutional Networks for Biomedical Image Segmentation[C]//Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015. Cham:Springer,2015:234-241.
https://doi.org/10.1007/978-3-319-24574-4_28.

[35] SUN X Z,XIE Y C,JIANG L M,et al. DMA-Net:DeepLab With Multi-Scale Attention for Pavement Crack

Segmentation[J]. IEEE Transactions on Intelligent Transportation Systems,2022,23(10):18392-18403. https://doi.org/10.1109/tits.2022.3158670.

[36] HAN C J,MA T,HUYAN J,et al. CrackW-Net:A Novel Pavement Crack Image Segmentation Convolutional Neural Network[J]. IEEE Transactions on Intelligent Transportation Systems,2022,23(11):22135-22144. https://doi.org/10.1109/tits.2021.3095507.

[37] QU Z,WANG C Y,WANG S Y,et al. A Method of Hierarchical Feature Fusion and Connected Attention Architecture for Pavement Crack Detection[J]. IEEE Transactions on Intelligent Transportation Systems,2022,23(9):16038-16047. https://doi.org/10.1109/tits.2022.3147669.

[38] YANG F,ZHANG L,YU S J,et al. Feature Pyramid and Hierarchical Boosting Network for Pavement Crack Detection[EB/OL]. arXiv,2019[2026-06-29]. https://arxiv.org/abs/1901.06340.

[39] 佃松宜,黄傲进,吴克江,等. TCS-Net:一种核电安全壳细小裂缝分割网络[J]. 工程科学与技术,2022,54(5):249-256. https://doi.org/10.15961/j.jsuese.202100590.

[40] 孟庆成,李明健,万达,等. 基于 M-Unet 的混凝土裂缝实时分割算法[J]. 土木与环境工程学报(中英文),2024,46(1):215-222.

[41] 杨燕泽,王萌,刘诚,等. 基于语义分割的沥青路面裂缝智能识别[J]. 浙江大学学报(工学版),2023,57(10):2094-2105.

[42] SHAMSABADI E A,XU C,RAO A S,et al. Vision transformer-based autonomous crack detection on asphalt and concrete surfaces[J]. Automation in Construction,2022,140:104316. https://doi.org/10.1016/j.autcon.2022.104316.

[43] CHEN Y H,GU X Y,LIU Z,et al. A Fast Inference Vision Transformer for Automatic Pavement Image Classification and Its Visual Interpretation Method[J]. Remote Sensing,2022,14(8):1877. https://doi.org/10.3390/rs14081877.

[44] LIU X,YANG X D,SHAO L H,et al. GM-DETR:Research on a Defect Detection Method Based on Improved DETR[J]. Sensors,2024,24(11):3610. https://doi.org/10.3390/s24113610.

[45] CHEN Z H,SHAMSABADI E A,JIANG S,et al. Vision Mamba-based autonomous crack segmentation on concrete,asphalt,and masonry surfaces[EB/OL]. arXiv,2024[2026-06-29]. https://arxiv.org/abs/2406.16518.

[46] TAN C,LIU J Q,ZHAO Z D,et al. ETAFHrNet:A Transformer-Based Multi-Scale Network for Asymmetric Pavement Crack Segmentation[J]. Applied Sciences,2025,15(11):6183. https://doi.org/10.3390/app15116183.

[47] LI G,WAN J,HE S H,et al. Semi-Supervised Semantic Segmentation Using Adversarial Learning for Pavement Crack Detection[J]. IEEE Access,2020,8:51446-51459. https://doi.org/10.1109/access.2020.2980086.

[48] SHIM S,KIM J,CHO G C,et al. Multiscale and Adversarial Learning-Based Semi-Supervised Semantic Segmentation Approach for Crack Detection in Concrete Structures[J]. IEEE Access,2020,8:170939-170950. https://doi.org/10.1109/access.2020.3022786.

[49] KIRILLOV A,MINTUN E,RAVI N,et al. Segment Anything[C]//2023 IEEE/CVF International Conference on Computer Vision(ICCV). Piscataway:IEEE,2023:3992-4003. https://doi.org/10.1109/iccv51070.2023.00371.

[50] ZHANG X N,WANG H L,HSIEH Y A,et al. Deep Learning for Crack Detection:A Review of Learning Paradigms,Generalizability,and Datasets[EB/OL]. arXiv,2025[2026-06-29]. https://arxiv.org/abs/2508.10256.

[51] WAN X L,JIANG X Y,LUO G S,et al. FlexiCrackNet:A Flexible Pipeline for Enhanced Crack Segmentation with General Features Transfered from SAM[EB/OL]. arXiv,2025[2026-06-29]. https://arxiv.org/abs/2501.18855.

[52] PARK S E,EEM S,JEON H. Concrete crack detection and quantification using deep learning and structured light[J]. Construction and Building Materials,2020,252:119096. https://doi.org/10.1016/j.conbuildmat.2020.119096.

[53] FAN Z H,LI C,CHEN Y,et al. Ensemble of Deep Convolutional Neural Networks for Automatic Pavement Crack Detection and Measurement[J]. Coatings,2020,10(2):152. https://doi.org/10.3390/coatings10020152.

[54] DENG P R,YAO J P,LI C,et al. Unified Few-shot Crack Segmentation and its Precise 3D Automatic Measurement

in Concrete Structures[EB/OL]. SSRN,2025.
https://doi.org/10.2139/ssrn.5135524.

[55] HARB S, ACHANCCARAY P, MABOUDI M, et al. Multi-temporal crack segmentation in concrete structures using deep learning approaches[J]. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences,2025,X-G-2025:341-348.
https://doi.org/10.5194/isprs-annals-x-g-2025-341-2025.

[56] MAEDA H, SEKIMOTO Y, SETO T, et al. Road Damage Detection and Classification Using Deep Neural Networks with Smartphone Images[J]. Computer-Aided Civil and Infrastructure Engineering, 2018, 33(12):1127-1141.
https://doi.org/10.1111/mice.12387.

[57] HUANG S Z, LIU Q, CHEN C, et al. A Real-time Concrete Crack Detection and Segmentation Model Based on YOLOv11[EB/OL]. arXiv, 2025[2026-06-29]. https://arxiv.org/abs/2508.11517.

[58] KIM B, CHO S. Automated vision-based detection of cracks on concrete surfaces using a deep learning technique[J]. Sensors,2018,18(10):3452.
https://doi.org/10.3390/s18103452.

[59] ARAFIN P, BILLAH A H M M, ISSA A. Deep learning-based concrete defects classification and detection using semantic segmentation[J]. Structural Health Monitoring,2024,23(1):383-409.
https://doi.org/10.1177/14759217231168212.

A Review of Deep Learning Applications in Concrete Crack Image Recognition and Surface Damage Assessment

QI Menglong

(School of Infrastructure Engineering, Dalian University of Technology, Dalian 116024, China)

Abstract: The morphology and evolution of concrete surface cracks can reflect material deterioration and structural stress conditions, making them important indicators for the inspection of bridges, tunnels, pavements, and building envelopes. In recent years, deep learning methods have been increasingly applied to crack image classification, object detection, semantic segmentation, instance segmentation, and geometric quantification, providing new technical pathways to non-contact inspection and digital maintenance. This review focuses on image-based concrete crack recognition and surface damage assessment, with particular attention to the applicability of convolutional neural networks(CNNs), transfer learning, one-stage object detectors, Faster R-CNN, Mask R-CNN, U-Net, DeepLab, Transformers, semi-supervised learning, and foundation models to different tasks. Studies have shown that classification models are suitable for rapid screening, object detection models emphasize crack localization, and pixel-level segmentation is more effective for morphological extraction and damage quantification. Current research is shifting from image-level recognition toward precise localization and pixel-level extraction; however, the measurement of actual geometric parameters and quantitative damage assessment remain insufficient. Dataset representativeness, annotation costs, cross-scenario generalization, scale calibration, and engineering validation are the main factors constraining practical application. Future research should strengthen lightweight deployment, annotation-efficient learning, multimodal measurement, and engineering validation to advance crack recognition toward quantitative damage assessment and maintenance decision support.

Keywords: Concrete crack; deep learning; image recognition; damage assessment; structural health monitoring

DOI: 10.48014/ems.20260722001

Citation: QI Menglong. A Review of Deep Learning Applications in Concrete Crack Image Recognition and Surface Damage Assessment[J]. Engineering Materials and Structures, 2026, 5(3): 127-139.

Copyright © 2026 by author(s) and Science Footprint Press Co., Limited. This article is open accessed under the CC-BY License (http://creativecommons.org/licenses/by/4.0/).