文章编号：0253-374X(2025)12-1887-11

DOI：10.11908/j.issn.0253-374x.24269

基于上下文自编码器–顺序层状耦合信息框架的设施表面缺陷多粒度识别与安全评价

柳本民[1]，李诚信[1,2]，林润达[2]，王鹤楠[2]，邓志成[2]，廖晨非[3]，李思维[4]

（1. 同济大学 交通学院，上海 201804；2. 上海发电设备成套设计研究院有限责任公司，上海 200240；
3. 香港科技大学(广州)，广东 广州 511442；4. 国核自仪系统工程有限公司，上海 201100）

摘要：提出了一种基于CAE_ViT网络模型和顺序层状耦合信息框架（sequential hierarchical coupled information framework，SHCIF）的多粒度多缺陷图像分类识别方法，并结合模糊综合评价（FCE）方法，以桥梁设施为例，对其表面缺陷进行细致的分类及安全评价。首先，研究提出了SHCIF及对应3个层次粒度的识别模型，并构建和增强了对应不同粒度的数据集。SHCIF框架和跨粒度分类决策旨在通过利用桥梁组件和缺陷类型这两个粒度的信息和准确性，提升对缺陷严重程度的识别。其次，使用迁移学习对CAE_ViT预训练模型进行微调，以满足桥梁缺陷检测的具体需求，并通过跨粒度分类决策进一步提升分类的准确性。最后，基于层次分析法与熵权法（AHP-EWM）的权重体系，通过模糊综合评价，综合考虑桥梁部位、桥梁组件、缺陷类型及其严重程度，实现了基于表观健康状态对桥梁安全状态等级的定量评价。实验结果显示，在3个层次粒度的识别模型中的宏平均F_1-Score分数分别达到94.1%、81.6%和75.3%，而跨粒度分类决策的准确率为82%。最终通过一个桥梁的安全评价案例证明了方法的有效性、系统性和可拓展性。

关键词：设施表观健康监测；桥梁缺陷检测；顺序层状耦合信息框架；上下文自动编码器算法；安全评价；模糊综合评价

中图分类号：TU997　　**文献标志码**：A

Multi-Grained Recognition of Facility Surface Defects and Safety Assessment Based on CAE-SHCIF

LIU Benmin[1], *LI Chengxin*[1,2], *LIN Runda*[2], *WANG Henan*[2], *DENG Zhicheng*[2], *LIAO Chenfei*[3], *LI Siwei*[4]

(1. College of Transportation Engineering, Tongji University, Shanghai 201804, China; 2. Shanghai Power Equipment Research Institute Co., Ltd., Shanghai 200240, China; 3. The Hong Kong University of Science and Technology (Guangzhou), Guangzhou 511442, China; 4. State Nuclear Power Automation System Engineering Co., Ltd., Shanghai 201100, China)

Abstract: A multi-granularity defect recognition and safety assessment method is proposed for facility surfaces, using bridges as a representative example. The approach integrates a CAE_ViT network model with a sequential hierarchical coupled information framework (SHCIF) and a fuzzy comprehensive evaluation (FCE) system. First, the SHCIF and three corresponding granularity-specific recognition models are established, with datasets constructed and augmented for each granularity level. The SHCIF and cross-granularity classification strategy are designed to enhance defect severity recognition accuracy by leveraging information from both bridge component and defect type granularities. Second, transfer learning is applied to fine-tune the CAE_ViT pre-trained model for bridge defect detection, with classification performance further improved through cross-granularity decision-making. Finally, an analytic hierarchy process-entropy weight method (AHP-EWM) weighting system is incorporated into the FCE to achieve quantitative safety assessment of bridges based on apparent surface conditions, considering bridge locations, components, defect types, and severity levels. Experimental results show macro-average F1-scores of 94.1%, 81.6%, and 75.3% for the three granularity levels, respectively, with cross-granularity classification reaching 82% accuracy. A case study on bridge safety evaluation demonstrates the effectiveness, systematicness, and extensibility of the method.

收稿日期：2024-08-19

基金项目：国家重点研发计划(2017YFC0803902)；云南公路资产管理项目(HAMP-CS-05)；中央高校基本科研业务费专项资金(22120230078)

第一作者：柳本民，副教授，博士生导师，工学博士，主要研究方向为交通安全与环境。
E-mail：liubenming@tongji.edu.cn

通信作者：李诚信，硕士生，助理工程师，主要研究方向为智能体与智慧场站巡检，多模态检测系统。
E-mail：lichengxintrans@tongji.edu.cn

论文拓展介绍

Keywords: facility surface health monitoring; bridge defect detection; sequential hierarchical coupled information framework (SHCIF); context autoencoder algorithm; safety assessment; fuzzy comprehensive evaluation (FCE)

在当前基础设施智慧化运维背景下,交通、土木、能源等领域的重要设施正面临着海量表面缺陷检测与系统性安全评价的共性挑战。传统人工巡检方法存在主观性强、效率低下、风险高且难以形成数字化档案等瓶颈,而现有深度学习检测方法多集中于单一缺陷识别,缺乏融合“精细识别-量化评估-安全评价”的理论方法。本文以桥梁这一典型复杂基础设施为研究对象,开展系统性方法构建与验证。桥梁管养需求在全寿命周期中具有高度代表性,尤其伴随我国特大跨径桥梁规模扩大与公众出行需求提升,其结构健康监测(SHM)的重要性日益凸显[1]。在通常的结构健康监测实践工作中,桥梁的目视检查主要基于工程师的直觉和专业知识,存在着主观判断有误差、繁琐耗时低效、人工成本高昂的问题。在检查过程中,检查者需要搭设脚手架且自身存在坠落等风险[2]。同时,具备丰富经验的检测人员日益稀缺,这也说明SHM迫切需要数字化缺陷识别技术的介入。随着深度学习在设施和系统结构进行结构健康检测领域的快速发展,面向桥梁缺陷的安全评价任务进行细粒度视觉分类(FGVC)或者超细粒度视觉分类(Ultra-FGVC)成为一种解决方案,可为桥梁表面损伤快速检测提供技术支撑[3]。CAE_ViT是一种基于上下文自动编码器(context autoencoder, CAE)的自监督学习算法[4],适用于细粒度和超细粒度的图像分类任务。其设计目的是通过重构输入图像的上下文信息来学习高质量的视觉表示,更好地捕捉图像中的局部和全局特征。ViT模型不需要像卷积神经网络那样固定感受野(Receptive Field)大小,它可以自适应地关注不同区域特征,使得在处理不同类型和尺度的缺陷时更为灵活。

如今,爬壁机器人和巡检无人机常被应用于桥梁病害或缺陷的检测[5],通过所拍摄的图像或者传感器信息进行后续的处理和安全风险评价[6]。目前,基于视觉或传感器信息,相关研究已经可以实现结构损伤识别[7]、缺陷损伤评估[8]、结构状态及可靠性评估[9]及结构寿命预测[10]。尽管缺陷识别在算法层面上取得了诸多的进步,但是存在着如下问题:①现有研究集中于单一的缺陷识别。涉及多种缺陷识别时,精度和效率都会下降。②研究集中于混凝土或者钢材等建筑材料的表面缺陷的分类识别。而实际上桥梁作为大型交通设施系统,其缺陷具有更复杂的风险影响,在识别缺陷后应进一步进行安全评价。③缺陷所在部件信息往往被忽视。即使是同一种缺陷,在不同部件位置,也会对桥梁整体可靠性有着不同的影响[11]。④现有缺陷分类识别模型对缺陷的不同严重程度及位置考虑的不够充分[8],未能将识别结果有效融入系统性安全评价。涉及到桥梁的缺陷病害时,桥梁风险的定义则更加聚焦于这些缺陷导致桥梁结构功能失效,从而可能造成的安全事故问题[12]。基于桥梁表面健康状态的安全风险评价,目前主要集中于赋权法和评价法的研究,如模糊层次分析法[13]、可拓评价模型[14]及熵权物元模型[15]等。这些研究虽在一定程度上推进了安全状态的量化评价,但仍缺乏与前端自动识别模型的联系。

综上所述,即使目前各类巡检机器人或无人机高速发展,但对于安全评价这一任务,缺乏系统性且可拓展的缺陷识别框架方法。本文研究提出了一种面向安全评价的设施表面缺陷自动分类方法,旨在通过深度学习技术实现对结构健康监测的自动化和精确化。以一个创新的多层次、多粒度的识别框架为核心,通过CAE_ViT网络模型对组件、缺陷类型及其严重程度进行分类。最终,使用模糊综合评价(FCE),实现基于表面健康状态对整体设施的安全状态等级进行评价。

1 顺序层状耦合信息框架设计

在桥梁缺陷识别分类的研究领域中,大多数研究集中于桥梁组件和某种单一缺陷类型的识别,这些研究往往忽略了多种缺陷类型和缺陷严重程度的识别。为解决这一难题,作者提出了顺序层状耦合信息框架(sequential hierarchical coupled information framework, SHCIF)。这一框架的设计理念是在传统的扁平状框架和顺序层状框架的基础上进行扩展和改进,不仅保留了顺序层状框架的分阶段处理思想,还通过耦合不同层次的信息来增强模型的分类能力。这里的耦合指的是在“桥梁组件”“桥梁组件-缺陷类型”和“缺陷类型-严重程度”3个识别模型之间存在信息的重叠和交互。通过设计不同层次之间的耦合信息,模型能够在分类过程中利用上下文信息,增强对细微差别的识别能力。同时,框架也对应后文层次分析法的层次结构,如图1所示。

为实现桥梁表面缺陷的精确识别与分级评估，构建了3个粒度层级递进的识别模型，分别对应组件识别、缺陷类型分类及严重程度评估。尽管模型间存在内在关联，但为清晰评估各模型性能并支持后续跨粒度决策策略，研究采用先独立训练再信息融合的路径。①Model 1“桥梁组件”粒度识别模型：该模型为整个框架的基础，其目的在于从图像中准确识别出桥梁的主要组件，包括桥面、梁体、支座和桥墩等关键结构部分。②Model 2“桥梁组件-缺陷类型”粒度识别模型：其在Model 1的基础上进一步细化，专注于识别桥梁组件上的具体缺陷类型。因为不同组件上的同种缺陷也存在差异以及为了耦合信息的学习，所以在Model 2中是将不同的“桥梁组件-缺陷类型”组合作为不同的类别进行学习。③Model 3“缺陷类型-严重程度”粒度识别模型：在Model 2成功识别出缺陷类型后，以“缺陷类型-严重程度”组合为类别，聚焦缺陷状态的量化分级，其训练标签依据现行标准并结合工程经验进行调整确定。

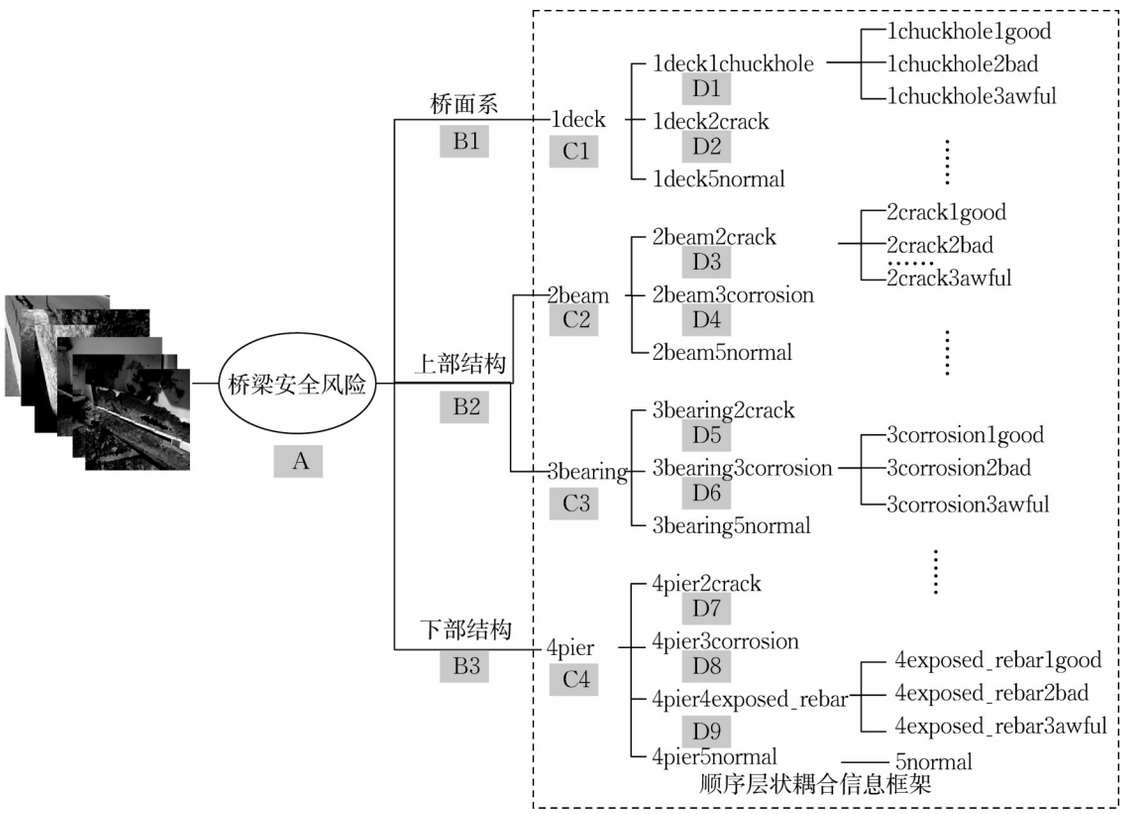

图1　顺序层状耦合信息框架及桥梁安全评价层次结构

Fig. 1　Sequential hierarchical coupled information framework and hierarchy of bridge safety assessment

本文对3个粒度识别模型均使用CAE_ViT_base这种较为轻量化的预训练模型进行迁移学习[16]，利用其在大规模图像中提取的通用特征，显著提升模型在小样本数据集上的收敛速度与识别效率，同时降低训练成本。

2　数据集构建

2.1　数据来源

本研究采用联合级图像作为主要数据源，该类图像通过中远距离拍摄捕捉桥梁整体结构，能够清晰呈现多种构件及其表面缺陷的关联形态，为桥梁状态评估提供关键信息[17]。但是这类图像存在着多种类型的结构元素相似或者在图片上叠加，以及图像中还会有多种复杂的背景图像的问题。原始数据来自于MLBID数据集[17]、CCSSSD数据集[18]、CODEBRIM数据集[19]、COCO-Bridge数据集[20]、Kaggle平台的Pothole Image Data-Set数据集[21]、TBID数据集[11]、SDNET2018数据集[22]、MCDS数据集[23]、BCIDS数据集[24]、CBCDS数据集[25]、

dacl10k Dataset数据集[26]、CSSC数据集[27]、SMSSD数据集[28]，通过网络抓取相关图片及作者手机拍摄进行图像数据的制作。

2.2 针对3个层级构建标签

对初步选取的图像，通过人工识别并按照既定类别进行标记，构建了基础数据集。所采用的原始标签系统涵盖了前文所述的桥梁组件、缺陷类型及严重程度3个层级的信息。

对于“桥梁组件”层级，主要针对桥梁的4种主要结构，分别为桥面铺装(标签：1deck)、梁体(标签：2beam)、支座(标签：3bearing)、桥墩(标签：4pier)，即通过组件的不同进行区分即可。对于“缺陷类型”层级，选取了桥梁的4类主要缺陷，分别为坑槽(标签：1chuckhole)、裂缝(标签：2crack)、腐蚀(标签：3corrosion)、露筋(标签：4exposed_rebar)，以及正常情况(标签：5normal)，即通过缺陷的不同或无缺陷来进行区分。对于“严重程度”层级，缺陷被划分为3个等级：轻微缺陷(标签：1good)、一般缺陷(标签：2bad)和严重缺陷(标签：3awful)。

2.3 针对3个粒度识别模型的数据集构建

通过3个层级对数据集打标签，形成包含3个层级的信息的“桥梁组件–缺陷类型–严重程度”的数据集Dataset 0，共计996张图片。典型图片如图2所示。

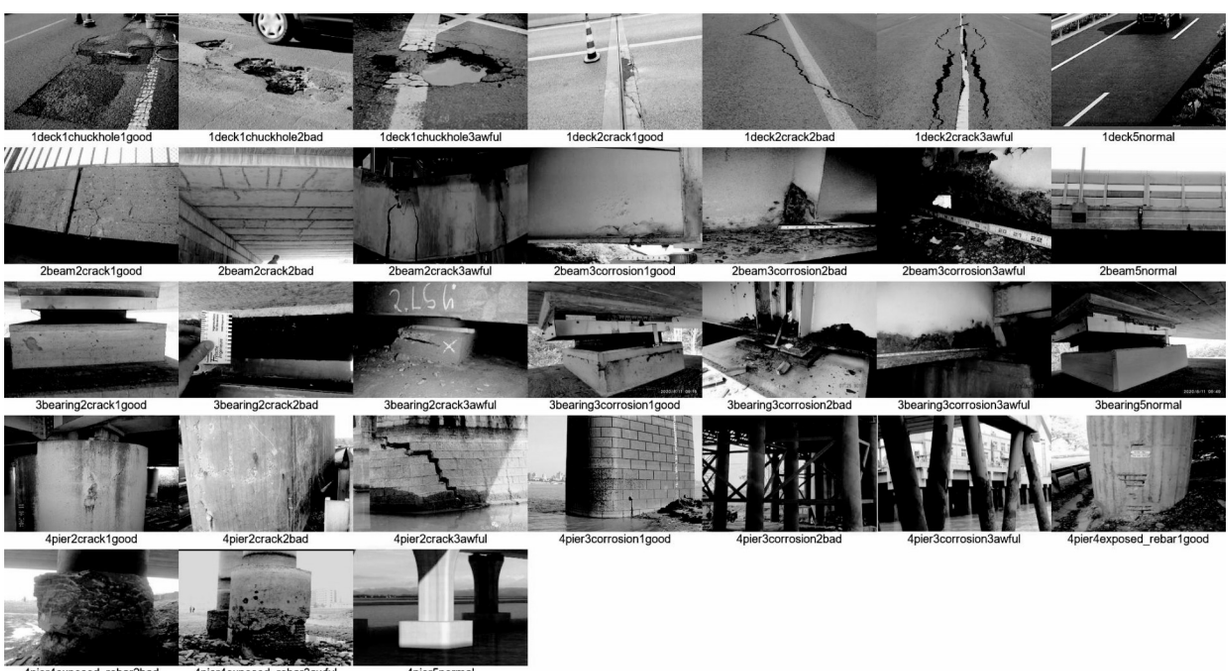

图2 数据集Dataset 0的典型图片

Fig. 2 Typical picture presentation of Dataset 0

对数据集进行梳理合并，分别构建3个粒度识别模型的数据集Dataset1、Dataset2及Dataset3。虽然不需要不同焦距的3张图片，但在同一张图像上可能存在多次标签的标注，以确保不同粒度的信息是对齐的。①“桥梁组件”粒度识别模型的数据集Dataset1在原始Dataset0基础上整合为4类组件图像，保留190张测试集，剩余806张训练集通过AutoContrast、Invert、Equalize、Color这4种针对颜色与亮度特征的增强算子扩充至4 030张，其中1 209张用于评估。②由于Dataset0组件存在部分的缺陷重叠等情况，“桥梁组件–缺陷类型”粒度识别模型的数据集Dateset2重新整理得到981张图片，取出175张作为测试集。剩余806张经过了AutoContrast、Equalize、Posterize、Color侧重形状与边缘特征的增强方法，同步扩充至4 030张图片，其中1 209张用于评估。③“缺陷类型–严重程度”粒度识别模型的数据集Dataset3通过补充样本至训练集851张、测试集225张。考虑到“缺陷类型–严重程度”粒度识别模型重点关注于缺陷的细微差别和空间位置，对新补充得到的851张训练数据集图像的每一个样本进行Rotate、FlipLR、TranslateX、TranslateY增强处理(step1)，得到4 255张图片。为了解决不平衡问题，对4 255张图片数据集中的小样本类别4exposed_rebar1good、1chuckhole1good、4exposed rebar3awful、1chuckhole2bad、4exposed rebar2bad、1chuckhole3awful进行Brightness、Sharpness、AutoContrast、

Equalize、Solarize_add 增强处理（step2），得到 7 180 张图片，其中 1 945 张用于评估。

除针对主要特征的数据增强以外，对一些次要特征也进行一定程度的微调。因此，在模型实际训练中，针对各任务特性实施二次增强：缺陷类型模型补充 ShearX/Y 以强化空间关系建模，严重程度模型则通过 Invert、Solarize、Posterize、Color 方法对缺陷的颜色特征与亮度特征进行再次增强。

3　基于 CAE-SHCIF 的实验与安全评价

3.1　CAE-SHCIF 子模型的训练

3.1.1　网络模型编译

网络模型编译的效果主要取决于损失函数、优化器和检测指标。损失函数采用交叉熵损失。优化器选用 Adam。在检测指标方面，由于在面对类别不平衡的情况下，单独使用准确率可能不足以全面评估模型的性能，因此进一步采用宏平均 F_1-Score 与宏平均召回率指标衡量模型性能。

3.1.2　超参数设置与训练

CAE_ViT 网络模型的设置见表 1。

3.1.3　多粒度模型的性能结果

本文引入 SHCIF 的核心目标是提高对“严重程度”这一精细层次的识别精度，便于后续的桥梁安全评价。为了验证耦合信息框架，利用较粗粒度图像信息作为先验，从而提升“严重程度”这一超细粒度图像分类准确性的优势，在研究中加入 Model 4 作为对照实验。具体来说，基于 Model 3 使用的数据集进行了重新整理，创建了一个新的数据集，该数据集仅对缺陷的不同严重程度进行了标注，而忽略了组件类型和缺陷类型的具体信息（即标签只包含 1good、2bad、3awful 及 5normal）。采用 CAE_ViT 网络模型，并沿用与 Model 3 相同的超参数设置进行训练。所有模型的训练性能结果见表 2，其中 Model 3 和 Model 4（对照实验）的对比揭示了耦合信息框架在提升分类性能方面的优势。

表 1　CAE_ViT 网络模型的设置

Tab. 1　Settings of CAE_ViT network

模型	超参数	再次增强
Model 1	InputSize：224,224；BatchSize：16；Epochs：50；BaseLearningRate：0.000015625	无
Model 2	InputSize：224,224；BatchSize：16；Epochs：50；BaseLearningRate：0.000015625	ShearX、ShearY
Model 3	InputSize：224,224；BatchSize：16；Epochs：50；BaseLearningRate：0.000015625	Invert、Solarize、Posterize、Color

表 2　CAE_ViT 网络模型的性能结果

Tab. 2　Performance of CAE_ViT network

模型	训练集			测试集		
	准确率/%	宏平均 F_1-Score/%	宏平均召回率/%	准确率/%	宏平均 F_1-Score/%	宏平均召回率/%
Model 1	99.8	99.8	99.8	93.5	94.1	93.7
Model 2	99.1	99.3	99.1	86.3	81.6	80.5
Model 3	96.9	96.7	96.6	75.6	75.3	73.6
Model4（对照实验）	87.1	85.2	85.1	53.7	53.0	49.1

仅依赖总体分类准确性可能会掩盖模型在某些类别上的性能不足。混淆矩阵可以帮助评估模型分类准确性和错误模式。图 3 为 3 个 Model 的混淆矩阵，用于总结分类器的性能。

根据图 3 混淆矩阵结果，可以得出：Model 1 在识别各个桥梁组件方面表现出色，这归功于模型能够有效捕捉和区分不同组件的特征。Model 2 在识别裂缝（标签：2crack）和露筋（标签：4exposed_rebar）时存在误判现象，这主要是因为裂缝和露筋在特征信息上具有较高的相似性。Model 3 在识别轻微缺陷（标签：1good）时准确率较高，但在区分一般缺陷（标签：2bad）和严重缺陷（标签：3awful）时面临一定的挑战，这是因为不同严重程度的缺陷在图像中的特征差异不够明显。然而，模型整体上倾向于预测更高的严重等级，这种保守的倾向为安全评价提供了更多的裕度，在风险领域是常见且可取的防控设计策略。

3.2　基于顺序层状耦合信息框架的跨粒度分类决策实验及结果分析

结合分类层次决策[23]和跨粒度的思路[29]，通过

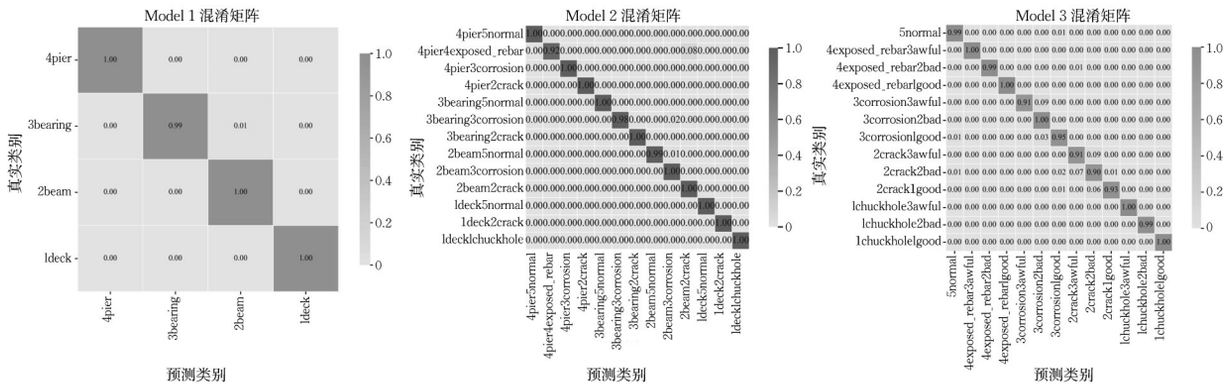

图3 3种模型中CAE_ViT网络模型的混淆矩阵

Fig. 3 Confusion matrix of CAE_ViT network in the three models

跨粒度分类决策策略实现多层级模型的信息融合。该框架建立上下文关联机制,使高层次分类结果(如桥梁组件)优先引导低层次决策(如缺陷类型与严重程度)。例如,桥梁组件的分类结果会影响缺陷类型的分类(因为Model 2中的类标签是包含组件信息的),而缺陷类型的分类结果又会影响缺陷严重程度的分类(因为Model 3中的类标签是包含缺陷信息的)。此外,若低层次模型对次高标签呈现高置信度而高层次对应标签置信度较低,则启动反向校验机制,但该机制优先级低于正向传递。同时,对于神经网络来说,设置超参数对于学习结果至关重要。网格搜索方法是搜索空间中的穷举方法,不适合大型超参数搜索。随机搜索比网络搜索更快,但超参数的组合可能会导致更差的结果。故本研究通过效率高、使用不同维度问题和规模以及序贯框架下的贝叶斯优化方法对超参数进行调整[30]。故最终的分类结果结合了各个阶段的信息,提升最终分类结果的正确率和可靠性,如图4所示。

为了测试跨粒度分类决策的效果,并且说明所选基于CAE_ViT的3个粒度的识别模型的鲁棒性,从另一套数据集three-level bridge surface information dataset[11]筛选出本研究涉及到的桥梁组件、缺陷或无缺陷、严重程度不同的图像样本50张。只有在3个粒度分类决策后,最终输出分类正确识别的图像才被认为是正确的(图5)。根据实验得到准确率(accuracy)为82%。对于分类错误,大多源自于第2、3个粒度模型(Model 2和Model 3)的错误。尽管制定了规则和标准对数据集进行打标签分类,但是由于人工分类存在一定的偏差,以及在判断不同严重程度的缺陷时存在一定的工程主观性[16],最终影响分类效果。当然,精确定位和量化损伤(例如,裂纹路径和密度)本身就具有较高的挑战性,这可以归因于训练数据集的潜在复杂性、其有限的大小以及由于源域(ImageNet数据集)和目标域(拟议的具体损伤数据集)之间的差异而导致的预训练网络的学习能力有限[31]。

3.3 基于层次分析法-熵权法-模糊综合评价的桥梁安全评价

3.3.1 通过AHP-EWM的权重构建

根据《公路桥梁技术状况评定标准》(JTG/T H21—2011)等规范,得出桥梁桥面系、上部结构、下部结构的权重分配 $W_A=(0.2,0.4,0.4)$。由于部位和组件是强绑定的关系,故由图像分类器得到组件层即可推知桥梁的部位,不需重复构建部位的分类模型。这也是层状框架的优势,在部件识别上可不再浪费资源[11]。

组件层权重和缺陷层权重构建是通过主客观相结合的赋权策略,运用层次分析法(AHP)与熵权法(EWM)得到的[32]。首先,邀请专家对桥梁表面缺陷的评价指标进行重要性打分(本次调查共向20名技术专家发放调查表并回收),形成初始打分矩阵。随后对数据进行标准化处理以消除量纲差异,区分正向与负向指标,并分别调整数据分布范围。其次,通过熵权法量化各指标的信息离散程度:计算指标熵值以反映其信息不确定性,再根据熵值得出差异系数,最终生成客观权重。同时,结合专家主观赋权结果,对主客观权重进行融合优化。从而构建兼顾经验与统计特性的综合权重体系,为安全评价提供量化依据。

最终整理计算得出各个桥梁部位下组件的权重向量分别为桥面系(包含C1桥面铺装)$W_{B1}=(1.00)$;上部结构(包含C2梁体及C3支座)$W_{B2}=(0.75,0.25)$以及下部结构(包含C4桥墩)$W_{B3}=(1.00)$。各个桥梁组件下缺陷的权重向量分

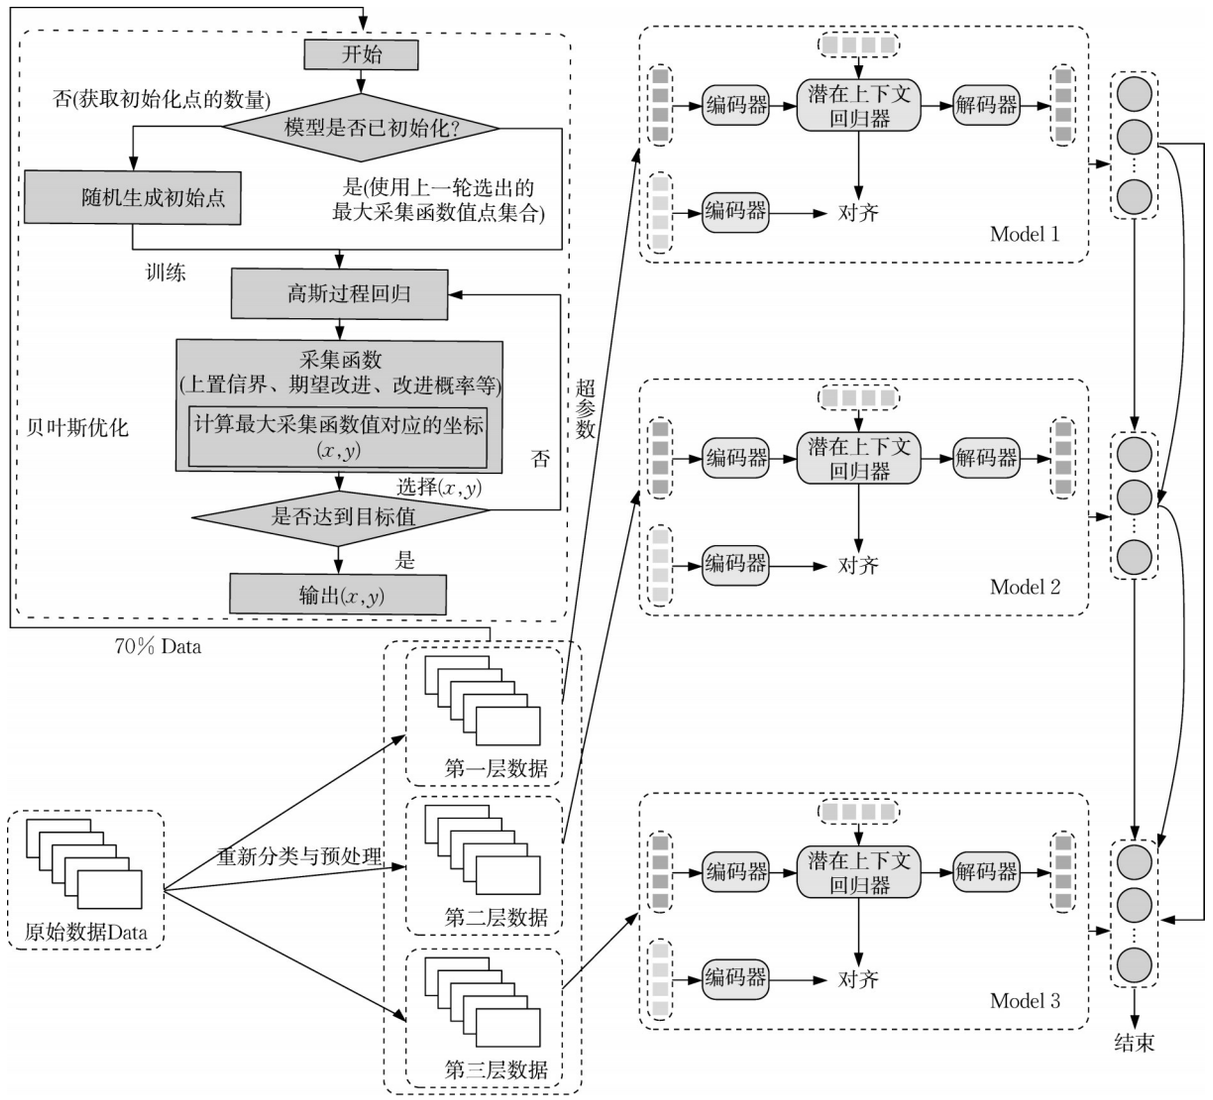

图4　基于CAE的跨粒度分类决策框架图

Fig. 4　Diagram of CAE-based decision-making framework for cross-granularity classification

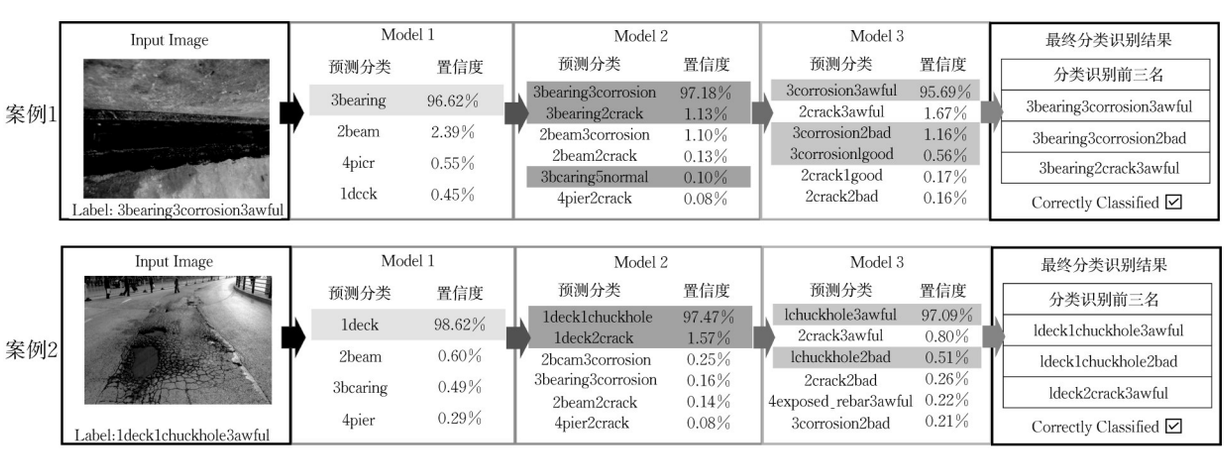

图5　基于顺序层状耦合信息框架的跨粒度分类决策过程

Fig. 5　Decision-making process for cross-granularity classification based on SHCIF

别为桥面铺装(包含D1桥面铺装坑槽、D2桥面铺装裂缝)$W_{C1}=(0.32,0.68)$；梁体(包含D3梁体裂缝、D4梁体腐蚀)$W_{C2}=(0.72,0.28)$；支座(包含D5支座裂缝、D6支座腐蚀)$W_{C3}=(0.76,0.24)$以及桥墩

(包含D7桥墩裂缝、D8桥墩腐蚀、D9桥墩露筋)$W_{C4}=(0.58, 0.11, 0.31)$。

3.3.2 基于FCE的评价体系构建

(1)单指标评价:针对本文构建的不同指标,建立其隶属函数或者对专家投票结果进行整理(某类别的投票数除以整体票数),进而对最底层指标进行评价。根据桥梁图片进行跨粒度分类,每张图片类比于一位专家("分类器专家"),基于一定的视角对桥梁的不同部位处的部件缺陷进行严重程度的评判。通过各类别的数量("分类器专家"的投票)来确定隶属度。通过这种方式,可以构建出隶属度矩阵为

$$\boldsymbol{R}=\begin{bmatrix} r_{11} & r_{12}\cdots r_{1n} \\ r_{21} & r_{22}\cdots r_{2n} \\ \vdots & \vdots & \vdots \\ r_{m1} & r_{m2}\cdots r_{mn} \end{bmatrix} \tag{1}$$

以C1桥面铺装组件下的D1桥面铺装坑槽和D2桥面铺装裂缝为例,对整个桥梁的图片进行跨粒度分类决策后,分别得到子类别的数量N_{D1}和N_{D2}以及不同严重程度的图片的个数,并满足:

$$N_{D1}=\sum N_{D1n}, n=1, 2, 3, 4 \tag{2}$$

$$N_{D2}=\sum N_{D2n}, n=1, 2, 3, 4 \tag{3}$$

使用模糊统计法,通过不同严重程度的图片与组件子类别的总数相比,得到对应的隶属度,并构成隶属度矩阵。具体如图6所示。

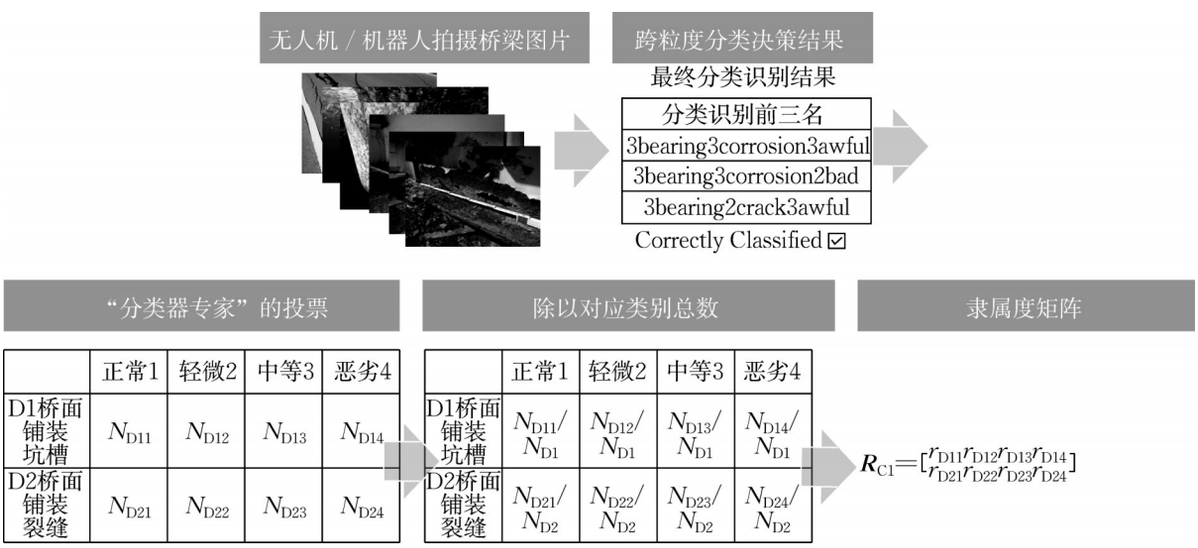

图6 分类器专家投票转化得到隶属度矩阵

Fig. 6 Transformation of classifier expert voting to get affiliation matrix

针对同层级的指标构建的隶属度矩阵,再将本层各个指标的权重与隶属度矩阵进行模糊计算,通过每层计算得到指标相对应的模糊向量[13]。

$$\boldsymbol{B}=\boldsymbol{W}_{1\times m}\circ\boldsymbol{R}_{m\times n}=(w_1\, w_2\cdots w_m)\begin{bmatrix} r_{11} & r_{12}\cdots r_{1n} \\ r_{21} & r_{22}\cdots r_{2n} \\ \vdots & \vdots & \vdots \\ r_{m1} & r_{m2}\cdots r_{mn} \end{bmatrix}= (b_1\, b_2\cdots b_n) \tag{4}$$

式中:"∘"为模糊合成算子,这里选择乘法-有界算子$M(\cdot, \oplus)$,能够较好地反映出评价的真实情况,与矩阵点乘结果一致。

(2)多指标评价:将评价向量$\boldsymbol{B}$构成隶属度矩阵与上文所得的各层权重进行模糊矩阵运算,得到最终的评价结果向量。参照技术状况标准中对桥梁进行四级安全性的评分划定,形成评价集为$V=(v_1, v_2, v_3, v_4)$。其中,(95,100]分为安全性一级,(85,95]分为安全性二级,(55,85]分为安全性三级,评分(0~55]分为安全性四级。为了简化计算,取每个评分范围的中点作为代表值,即:安全性一级桥梁代表评分97.5分、安全性二级桥梁代表评分90.0分、安全性三级桥梁代表评分70.0分以及安全性四级桥梁代表评分27.5分。由最终的评价结果向量,根据加权平均原则,确定桥梁安全状态等级。

3.3.3 实例分析

以上海某大桥的主桥段为例,根据该桥梁的检测报告及图像数据集,进行实例分析。收集到的图像数据集来自手机拍摄或者巡检智能体拍摄。整理得到本文涉及到的4种主要组件的图片,通过分类器得到不同图片的缺陷和严重程度,并通过3.3.2节提及的模糊统计法,基于不同类别图片的数量进

行缺陷层的隶属度矩阵向量构建。

(1)缺陷层：基于缺陷的隶属度矩阵向量，构建桥梁组件下缺陷的模糊关系矩阵，结合各个桥梁组件下缺陷的权重分配，计算得到各缺陷的模糊综合评价向量，结果如表3所示。

(2)组件层：根据表3建立组件层模糊关系矩阵，结合各个桥梁部位下组件的权重分配，计算得到各组件的模糊综合评价向量，结果如表4所示。

(3)部位层：根据表4建立部位层模糊关系矩阵，结合桥面系、上部结构、下部结构的权重分配，计算得到桥梁最终的模糊综合评价向量，结果如表5所示。

根据加权平均原则计算最终评价分数：

$$S=0.59\times 97.5+0.25\times 90.0+0.14\times 70.0+0.02\times 27.5=90.38 \tag{5}$$

根据这个计算结果，由于90.38分位于85～95分的范围内，根据给出的评分标准，这个桥梁的安全等级应该被划分为安全性二级桥梁。这与原检测报告给出的检测结果一致。

表3　缺陷层权重、隶属度及组件模糊综合评价向量

Tab. 3　Weights of defect layer, affiliation and vector operations of fuzzy comprehensive evaluation for components

缺陷	缺陷权重	隶属度			
		正常1	轻微2	一般3	严重4
D1桥面铺装坑槽	0.32	0.63	0.26	0.07	0.05
D2桥面铺装裂缝	0.68	0.39	0.29	0.27	0.04
模糊综合评价向量		0.47	0.28	0.21	0.04
D3梁体裂缝	0.72	0.55	0.29	0.15	0.02
D4梁体腐蚀	0.28	0.61	0.29	0.09	0.01
模糊综合评价向量		0.56	0.29	0.13	0.01
D5支座裂缝	0.76	0.64	0.26	0.08	0.02
D6支座腐蚀	0.24	0.62	0.23	0.13	0.02
模糊综合评价向量		0.64	0.25	0.10	0.02
D7桥墩裂缝	0.58	0.69	0.14	0.16	0.01
D8桥墩腐蚀	0.11	0.69	0.21	0.09	0.02
D9桥墩露筋	0.31	0.63	0.29	0.06	0.01
模糊综合评价向量		0.67	0.20	0.12	0.01

表4　组件层权重、隶属度及部位模糊综合评价向量

Tab. 4　Weights of component layer, affiliation, and vector operations of fuzzy comprehensive evaluation for parts

组件	组件权重	隶属度			
		正常1	轻微2	一般3	严重4
C1桥面铺装	1.00	0.47	0.28	0.21	0.04
模糊综合评价向量运算		0.47	0.28	0.21	0.04
C2梁体	0.75	0.56	0.29	0.13	0.01
C3支座	0.25	0.64	0.25	0.10	0.02
模糊综合评价向量运算		0.58	0.28	0.12	0.02
C4桥墩	1.00	0.67	0.20	0.12	0.01
模糊综合评价向量运算		0.67	0.20	0.12	0.01

表5　部位层权重、隶属度及桥梁最终模糊综合评价向量

Tab. 5　Weights of part layer, affiliation, and vector operations of fuzzy comprehensive evaluation for the whole bridge

部位	部位权重	隶属度			
		正常1	轻微2	一般3	严重4
B1桥面系	0.20	0.47	0.28	0.21	0.04
B2上部结构	0.40	0.58	0.28	0.12	0.02
B3下部结构	0.40	0.67	0.20	0.12	0.01
模糊综合评价向量运算		0.59	0.25	0.14	0.02

4 结论

研究以桥梁为典型对象,针对基础设施表面缺陷的多粒度识别与安全评价需求,提出了一种基于CAE_ViT算法和顺序层状耦合信息框架的通用自动化方法。结合模糊综合评价,构建了一套基于表观图像数据的设施缺陷识别与安全状态评估体系,并进行了验证。该方法通过多粒度图像分析实现了设施健康状态的层次化评估,为基础设施智慧运维提供了可扩展的技术路径。主要结论如下:

(1)通过引入SHCIF框架,将缺陷严重程度这一关键粒度纳入分类器中。同时通过跨粒度分类决策,利用前两个粒度分类器的信息和准确性提升对缺陷严重程度这一粒度的识别准确率。

(2)所提方法在桥梁场景的3个粒度识别模型中的宏平均F_1-Score分别达到94.1%、81.6%和75.3%,跨粒度分类决策的准确率最终达到82%。这些结果证明了所提方法的有效性和优越性。

(3)基于层次分析法与熵权法的权重体系,通过模糊综合评价实现了通过桥梁表观健康状态对桥梁的安全状态等级进行定量评价。通过"分类器专家投票"机制构建隶属度矩阵,实现了设施安全状态的量化评价。实例分析结果与检测报告一致,表明该方法具备良好的工程适用性。

尽管研究取得了一定成果,但仍存在一些局限性。例如,数据集中的人工标注可能存在偏差,且对于不同严重程度缺陷的判断可能具有工程主观性。此外,预训练网络的学习能力可能受到源域和目标域差异的限制。未来的研究可从以下几个方面进一步优化:一是扩充数据集,覆盖更多设施类型、组件与缺陷场景,提升数据多样性与标注一致性;二是考虑将安全评价模型直接嵌入深度学习网络中,实现识别-评价端到端一体化建模及管理平台集成[33];三是探索更加先进的迁移学习技术[34],进一步提升模型识别能力。

作者贡献声明:

柳本民:基金支持,研究选题,论文审定。

李诚信:撰写论文初稿,修改意见回复,实验开展,结果分析。

林润达:结果讨论,数据分析。

王鹤楠:结果讨论,数据分析。

邓志成:论文审定,结果讨论。

廖晨非:数据验证,论文润色。

李思维:论文润色,案例分析。

参考文献:

[1] 黄宁宁. 基于机器视觉的桥梁表面缺陷检测方法研究与实现[D]. 重庆: 西南大学, 2022.
HUANG Ningning. Research and implementation of bridge surface defect detection method based on machine vision[D]. Chongqing: Southwest University, 2022.

[2] YANG S, HUANG Y. Damage identification method of prestressed concrete beam bridge based on convolutional neural network[J]. Neural Computing and Applications, 2021, 33(2): 535.

[3] ZHANG Y, YUEN K V. Review of artificial intelligence-based bridge damage detection [J]. Advances in Mechanical Engineering, 2022, 14(9): 16878132221122770.

[4] CHEN X, DING M, WANG X, *et al*. Context autoencoder for self-supervised representation learning [J]. International Journal of Computer Vision, 2023, 132(1): 208.

[5] POTENZA F, RINALDI C, OTTAVIANO E, *et al*. A robotics and computer-aided procedure for defect evaluation in bridge inspection [J]. Journal of Civil Structural Health Monitoring, 2020, 10(3): 471.

[6] 刘宇飞, 冯楚乔, 陈伟乐, 等. 基于机器视觉法的桥梁表观病害检测研究综述[J]. 中国公路学报, 2024, 37(2): 1.
LIU Yufei, FENG Chuqiao, CHEN Weile, *et al*. Review of bridge apparent defect inspection based on machine vision[J]. China Journal of Highway and Transport, 2024, 37(2): 1.

[7] DENG W, MOU Y, KASHIWA T, *et al*. Vision based pixel-level bridge structural damage detection using a link ASPP network[J]. Automation in Construction, 2020, 110: 102973.

[8] FLAH M, SULEIMAN A R, NEHDI M L. Classification and quantification of cracks in concrete structures using deep learning image-based techniques [J]. Cement and Concrete Composites, 2020, 114: 103781.

[9] TARABEN J, HELMRICH M, MORGENTHAL G. Datenmodelle für digitale zwillinge von brücken und bildbasierte zustandsaufnahmen[J]. Bautechnik, 2022, 99(2): 134.

[10] YUAN M, LIU Y, YAN D, *et al*. Probabilistic fatigue life prediction for concrete bridges using bayesian inference [J]. Advances in Structural Engineering, 2019, 22(3): 765.

[11] ZHANG H, SHEN Z, LIN Z, *et al*. Deep learning-based automatic classification of three-level surface information in bridge inspection[J]. Computer-Aided Civil and Infrastructure Engineering, 2024, 39(10): 1431.

[12] ALIYARI M, ASHRAFI B, AYELE Y Z. Hazards identification and risk assessment for UAV - assisted bridge inspections [J]. Structure and Infrastructure Engineering, 2022, 18(3): 412.

[13] 王冰. 中小跨径桥梁智能安全风险等级评价及养护措施研究[D]. 西安: 西安理工大学, 2022.
WANG Bing. Study on intelligent safety risk assessment grade and maintenance measures of medium and small span bridges [D]. Xi'an: Xi'an University of Technology, 2022.

[14] 张延年，柳成林，李玉兵，等. 基于多指标多级可拓评价的混凝土桥梁桥面体系状态评估[J]. 公路交通科技，2016，33(3)：52.
ZHANG Yannian，LIU Chenglin，LI Yubing，*et al*. Assessment of condition of concrete bridge deck system based on multi-index multi-level extension assessment[J]. Journal of Highway and Transportation Research and Development，2016，33(3)：52.

[15] 张阳，刘佳，梁攀，等. 基于熵权可拓物元模型的桥梁检测指标综合评定[J]. 长安大学学报(自然科学版)，2022，42(6)：42.
ZHANG Yang，LIU Jia，LIANG Pan，*et al*. Comprehensive evaluation of bridge inspection indexes based on entropy weight extension matter- element model[J]. Journal of Chang'an University(Natural Science)，2022，42(6)：42.

[16] GAO Y，MOSALAM K M. Deep transfer learning for image-based structural damage recognition[J]. Computer-Aided Civil and Infrastructure Engineering，2018，33(9)：748.

[17] ZHANG C，KARIM M M，QIN R. A multitask deep learning model for parsing bridge elements and segmenting defect in bridge inspection images[J]. Transportation Research Record，2023，2677(7)：693.

[18] Virginia Polytechnic Institute and State University. Corrosion condition state semantic segmentation dataset[R]. Blacksburg：Virginia Polytechnic Institute and State University，2021.

[19] MUNDT M，MAJUMDER S，MURALI S，*et al*. Meta-learning convolutional neural architectures for multi-target concrete defect classification with the concrete defect bridge image dataset[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach：IEEE Press，2019：11188-11197.

[20] BIANCHI E，ABBOTT A，TOKEKAR P，*et al*. COCO-bridge：structural detail data set for bridge inspections[J]. Journal of Computing in Civil Engineering，2021，35：4021003.

[21] PATEL S. Pothole image dataset[EB/OL]. [2024-06-14]. https://www. kaggle. com/datasets/sachinpatel21/pothole-image-dataset.

[22] 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.

[23] HÜTHWOHL P，LU R，BRILAKIS I. Multi-classifier for reinforced concrete bridge defects[J]. Automation in Construction，2019，105：102824.

[24] LI B，GUO H，WANG Z，*et al*. Automatic crack classification and segmentation on concrete bridge images using convolutional neural networks and hybrid image processing[J]. Intelligent Transportation Infrastructure，2022，1：1.

[25] ZOUBIR H，RGUIG M，ELAROUSSI M. Crack recognition automation in concrete bridges using deep convolutional neural networks[J]. MATEC Web of Conferences，2021，349：03014.

[26] FLOTZINGER J，RÖSCH P J，BRAML T. Dacl10k：benchmark for semantic bridge damage segmentation[C]//2024 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). Waikoloa：IEEE Press，2024：8611-8620.

[27] YANG L，BING L，WEI L，*et al*. Deep concrete inspection using unmanned aerial vehicle towards CSSC database[C]//2017 IEEE/RSJ International Conference on Intelligent Robots and Systems. Vancouver：IEEE Press，2017：202667196.

[28] Virginia Polytechnic Institute and State University. Structural material semantic segmentation dataset[R]. Blacksburg：Virginia Polytechnic Institute and State University，2021.

[29] PANG W，SONG W. Cross-granularity fusion network for fine-grained image classification[C]//2023 4th International Seminar on Artificial Intelligence，Networking and Information Technology (AINIT). Nanjing：IEEE Press，2023：617-622.

[30] SNOEK J，LAROCHELLE H，ADAMS R P. Practical bayesian optimization of machine learning algorithms[C]//Proceedings of the 25th International Conference on Neural Information Processing Systems. Red Hook：Curran Associates Inc，2012：2951-2959.

[31] ZOUBIR H，RGUIG M，EL AROUSSI M，*et al*. Concrete bridge defects identification and localization based on classification deep convolutional neural networks and transfer learning[J]. Remote Sensing，2022，14(19)：4882.

[32] 费金池. 西北干寒地区中小型梁桥安全风险评价研究[D]. 兰州：兰州交通大学，2021.
FEI Jinchi. Research on safety risk assessment of small and medium beam bridges in northwest China[D]. Lanzhou：Lanzhou Jiaotong University，2021.

[33] 李诚信，赵伟，李千，等. 疲劳监测技术在智慧矿山安全管理中的应用[J]. 煤炭科学技术，2021，49(增刊1)：131.
LI Chengxin，ZHAO Wei，LI Qian，*et al*. Application of fatigue monitoring technology in smart mine safety management[J]. Coal Science and Technology，2021，49(S1)：131.

[34] SINGH S A，CHOUDHARI S J，DESAI K A. Augmenting human-guided progressive learning with machine vision systems for robust surface defect detection[J]. Advanced Engineering Informatics，2024，62：102906.