

基于全卷积神经网络的结构健康监测数据异常诊断方法

闰金明, 夏云霞*, 张云龙, 程岩峰, 倪一清

(青岛理工大学 土木工程学院, 青岛 266525)

摘要: 为了消除人工检查或常规的信号处理技术在结构健康监测 (SHM) 数据异常诊断过程中费力耗时的弊端, 提出基于全卷积神经网络 (FCN) 进行 SHM 异常数据类型的分类。改进 GoogLeNet 预训练模型, 在 GoogLeNet 网络基础上构建全卷积单元代替全局平均池化和全连接层, 简化训练参数的同时提高模型精确度。在某悬索式吊桥的 SHM 系统集成的应变数据上, 随机选取监测数据组成数据集, 进行模型分类性能测试。研究表明, FCN 网络模型的分类测试准确率达到 98.6%, 训练时间仅为原 GoogLeNet 模型的 2/3, 训练效果优异。

关键词: 结构健康监测; 异常诊断; 全卷积神经网络; 应变监测数据

中图分类号: TU317 文献标志码: A 文章编号: 1673-4602(2025)04-0039-07

The diagnostic method for data anomaly in structural health monitoring based on fully convolutional neural network

RUN Jinming, XIA Yunxia*, ZHANG Yunlong, CHENG Yanfeng, NI Yiqing

(School of Civil Engineering, Qingdao University of Technology, Qingdao 266525, China)

Abstract: In order to overcome the laborious and time-consuming aspects of manual inspection or conventional signal processing techniques in the diagnosis of data anomaly in structural health monitoring (SHM), a classification approach for SHM abnormal data types based on fully convolutional neural network (FCN) is proposed. The GoogLeNet pre-trained model is improved, and fully convolutional units are constructed on the basis of GoogLeNet network to replace global average pooling and fully connected layers. While the training parameters are simplified, the accuracy of the model is enhanced. Based on the strain data integrated into the SHM system of a cable-stayed bridge, some monitoring data are randomly selected to form a dataset for the classification performance testing of the model. The results show that the classification accuracy of the FCN network model reaches 98.6%, and the training time is only 2/3 of the original GoogLeNet model, exhibiting excellent training performance.

Key words: structural health monitoring (SHM); anomaly diagnosis; fully convolutional neural network (FCN); strain monitoring data

收稿日期: 2023-12-21

基金项目: 山东省自然科学基金 (ZR2023ME105)

作者简介: 闰金明 (2000—), 男, 山东德州人。硕士, 研究方向为结构健康监测。E-mail: 2229481498@qq.com。

* 通信作者: 夏云霞 (1986—), 女, 山东潍坊人。博士, 副教授, 主要从事结构健康监测、结构振动理论与应用等方面的研究。
E-mail: xiayunxia@qut.edu.cn。

结构健康监测 (Structural Health Monitoring, SHM) 系统能对环境、荷载状况和结构响应进行实时监测^[1-4]。然而,桥梁结构在服役期间受环境因素激励影响较大,系统将不可避免地混杂异常数据,严重影响结构的行为^[5]。传统的检查方法费时耗力^[6],因此,高效的异常数据诊断成为结构健康监测领域的重点内容。近年来,深度学习逐步在提取数据中潜在复杂模式方面展示了优越的性能,常被提出应用于计算机视觉和深度学习的图像分类和目标检测^[7-11]。BAO 等^[12]将时间序列转换为图像向量,输入到深层神经网络中实现了 87.0% 的检测精度。TANG 等^[13]将时间序列储存在包含时频域的二维图像中,在 SHM 数据异常分类上达到 93.5% 的总体准确率。但仍有大量数据没有被正确识别,且在训练速度上有欠缺。全卷积网络 (Fully Convolutional Neural Network, FCN) 能实现从图像像素到像素类别的变换,并简化网络参数量^[14]。CAO 等^[15]将 101 层和 152 层深度残差网络体系结构结合全卷积网络实现了图像的深度估计。DUNG 等^[16]提出将深度 FCN 用于混凝土裂缝图像的语义分割,证明了 FCN 的合理性和准确性。FCN 模型在语义分割领域展示出较好的效果,而在图像分类领域鲜有使用。本研究考虑利用 FCN 模型中的结构单元改进 GoogLeNet 网络结构用于图像分类,提出一种基于 FCN 的 SHM 数据的异常诊断方法,以 GoogLeNet 网络模型为基础,构建完全卷积网络,但其中的转置卷积、上采样等操作在本文中不予采用,并以 Elu 激活函数代替目前较常用的 Relu 激活函数,进一步提高分类性能,并应用于一座悬索式吊桥的 SHM 系统数据集上,所提方法有较好的效果。

1 SHM 数据异常诊断及原理

如图 1 所示,所提出的 SHM 数据异常诊断方法步骤如下:①将 SHM 原始时间序列在时域进行可视化,再转换为灰度图像。将应变数据在时间上的响应转换、储存到对应的灰度图像中,后续依据图形特征分别标记。②模型架构在 GoogLeNet 预训练模型基础上进行了改进,以应变数据集作为输入,得到充分训练后的全卷积神经网络。③随机选取未识别的应变图像组成测试集,测试模型分类性能。

1.1 数据转换

在前期的数据处理过程中,需将 SHM 原始监测数据转换为图像,评估数据质量,而不能直接将原始时间序列输入到模型中去。本文每个单通道图像均采用 8 位灰度,图像分辨率均为 100×100 像素。随机选取应变数据转换的图像组成训练集和验证集,即作为 CNN 模型的输入。随机选取剩余的应变图像组成测试集,用于模型最终性能评估的分类性能测试。异常数据转换的图像具有突出的图形空间特征,通过深度学习模型便能够清晰地识别出来。

1.2 GoogLeNet 网络

GoogLeNet 是一种全新的卷积神经网络结构,同 LeNet、AlexNet、VGGNet 和 ResNet 等其他经典网络模型一样广泛应用于图像处理领域^[17]。GoogLeNet 网络模型具有以下特点:①引入区域分类器 Inception 结构(图 2),把多个卷积操作放在一个网络模块中,旨在找出神经网络中

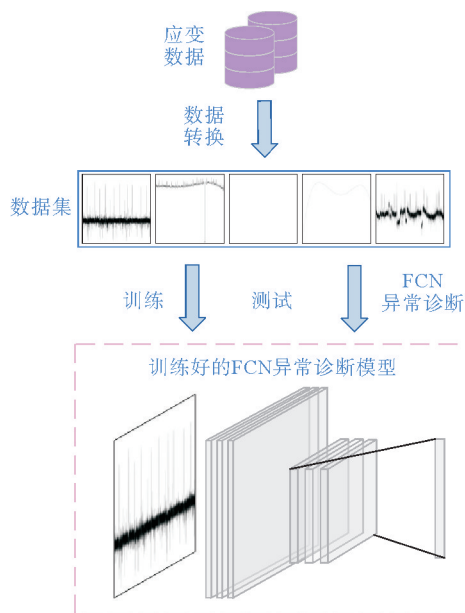


图 1 基于 FCN 模型的 SHM 数据异常诊断方法流程




图 2 Inception 区域分类结构

最优的局部稀疏结构,并能重复利用这种结构,从而融合不同尺度的特征信息;②采用 1×1 卷积核用作降维模块,消除计算瓶颈;③使用全局平均池化简化模型参数。

1.3 FCN 框架

本文选用 GoogLeNet 的 Inception 模块作为网络主体结构的组成部分,所提出的模型架构及参数如图 3 所示。确定网络的输入尺寸为 $100 \times 100 \times 1$ 像素的图像,网络的最终输出尺寸为 $1 \times 1 \times 5$ 像素。第 1 层(L1)设计为相同大小的输入层,图像尺寸为 $100 \times 100 \times 1$ 像素。第 2 层(L2)是 FCN 的特征提取层,重复使用 Inception 结构,在提取层设置不同尺寸的滤波器,基于不同通道充分提取输入的多种特征。第 3 层(L3)是尺寸为 $1 \times 1 \times 5$ 像素的全卷积层,综合卷积、激活、池化得到的局部特征,重新通过权值矩阵组装成完整的图。第 4 层(L4)是输出层,即分类层,这一层的作用是一个 5×1 像素的分类器,分类器的输出节点等于图像集类别数量。




图 3 FCN 模型架构及参数示意(单位:像素)

1.3.1 全卷积单元

卷积神经网络(Convolutional Neural Network, CNN)模型通常由输入层、多个卷积模块层、一个全连接层以及输出层架构而成,每个卷积模块在模型训练过程中进行卷积、激活及池化操作。在卷积过程中,一个卷积核只捕捉输入数据中的一种特定的局部特征,因此,如果要提取多种特征,就需要使用多个不同的卷积核。若是使用 5 个不同的卷积核组成 1 个滤波器,则输出 5 个特征图。本文设置卷积核的数量依次为 64、192、480、832、1024 个。通过局部连接和权值共享对高维输入数据实施降维处理,能实现自动提取不同分量和更深层次的特征。

一般的深度网络只能计算一般的非线性函数,而 FCN 可以计算非线性滤波器。传统的卷积神经网络的输出一般都是概率值,全连接层用于高度提取特征,方便交给最后的分类器进行概率分类。全连接层可以视为一种特殊的卷积层,但其参数数量却是经过全卷积单元计算的参数数量的几倍。例如,本文网络输入尺寸为 $100 \times 100 \times 1$ 像素,那么一个全连接的神经网络经过全连接层的参数总数为 46 085 个,而经过全卷积单元的参数总数仅为 5125 个。对于任意一个卷积层,都存在一个全连接层以实现网络的前向传播,即任意一个全连接层都能被卷积层转化。因此,可以用卷积层代替全连接层。

1.3.2 激活函数

激活函数是神经网络中的一个重要部分,它将卷积层的输出结果非线性化,从而提升神经网络的拟合能力,使得模型能拟合更复杂的函数。本文采用修正线性单元 Relu、渗透修正线性单元 LeakyRelu、指数线性单元 Elu 作为神经网络的激活函数,它们在定义域中均是连续可导的。激活函数如图 4 所示,Elu 函

数同时具有 Relu 和 LeakyRelu 函数的优点,在正数区域不饱和,且输出均值更接近于 0,同时解决了函数在负数区域被杀死的问题。




图4 激活函数

2 实验研究

2.1 数据集

鉴于本研究需大量数据训练验证网络模型,使用了在某悬索式吊桥上 SHM 系统实际监测的应变数据。该系统包含 30 个应变传感器,采样频率均为 51.2 Hz,监测数据 1 年全覆盖。原始监测数据按小时平均切割成若干片。将所有数据切片通过数据转换进行可视化操作,该过程中通过去趋势化操作忽略温度对应变和加速度数据的影响,继而将图像处理为 100×100 像素的单通道灰度图像,人工标记不同类型并将结果保存于相应类型文件夹。其中,应变数据集包括 5 个不同类别,分别为正常、跳点、缺失、次小和偏移。应变数据集的标签按顺序由 1—5 给出。

传感器一般布置在桥梁最主要受力构件上,其测得的数据应能充分反映桥梁的动态特性。根据传感器在桥梁上的布置位置分以下两种情形:①当应变传感器布置于桥梁顶部时,以受压为主,应变图像示例如图 5(a)所示;②当应变传感器布置于桥梁底部时,以受拉为主,应变图像示例如图 5(b)所示。

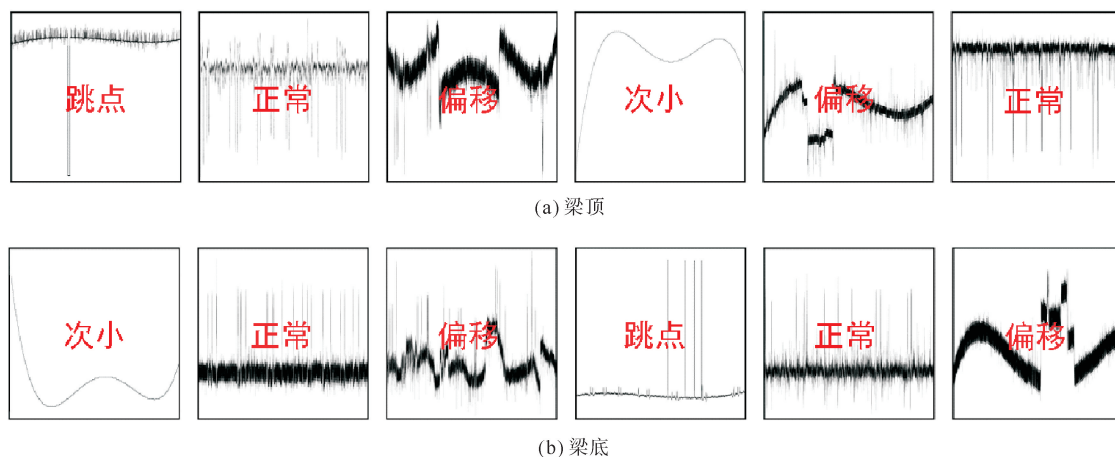


图5 位于梁顶和梁底的应变图像示例

实际上,SHM 系统中大多数数据都是未标记的。对于 CNN 来说,使用越多标注数据,分类器的性能越好。一般来说,CNN 训练需要一个庞大的数据集,但数据集标注的成本无疑是昂贵的,且目前还没有供 SHM 领域使用的公共已标注数据集。本文设计了有监督学习的 FCN 网络模型作分类器,需要一个有大量数据标注的数据集。因此,本研究首先对应变数据集进行标注,得到包含 5 种数据类型在内的 52 972 个标注数据,随机选取各个类型的数据集数量分布情况如表 1 所示。为解决分布严重不均衡问题,本研究

引入图像增广技术,通过对比度增强、添加噪声等操作,对数据进行一系列的相似化处理,扩充数据集的规模,缓解不均衡分布对训练性能的压力。

2.2 训练相关设置

在一般的二分类或多分类问题中,对训练好的模型进行性能评估,是模型开发过程中不可或缺的一部分。数据集按照“目标类”和“输出类”2 个标准进行汇总。准确率、精度、召回率、F1 分数是最常用的模型评价指标。准确率是最直观简单的评价指标,通常作为分类问题的总体评估。精度和召回率分别是针对预测结果和真实样本而言的。F1 分数是精度和召回率的调和平均值,其值越大,说明模型性能越好。

在配置为 12th Gen Intel(R)Core(TM)i7-12700 2.10 GHz 和 16 GB 内存的服务器上进行训练, GPU 为 NVIDIA GeForce RTX 3070Ti。本研究使用 MATLAB 2019b 软件生成数据集并搭建网络模型。在 FCN 模型训练过程中,选用带有动量的随机梯度下降 sgdm 优化器进行优化,初始学习率为 0.000 01,训练时采用批处理,最小批处理 MiniBatchSize 为 48,全局最大迭代次数为 30 次,L2 正则化系数为 0.03,设置每迭代 3 次学习率就降为原来的 90%。同时,训练时每迭代 1 次就打乱 1 次训练数据,随着模型训练的不断迭代,就不再有准确率上升及损失下降的趋势,而是处于相对稳定阶段,其中,损失是指模型所作出的预测结果离真实值的偏离程度。

3 结果与讨论

3.1 采用不同激活层的结果比较

激活函数具有非线性,负责将神经元的输入映射到输出端。图 6 展示了在 3 种不同激活层下的 FCN 模型训练准确率和损失的结果比较。由图 6 可见,本研究所提出的 FCN 模型的验证准确率均达到 95%以上,验证损失控制在 0.2 以下。在表 2 的结果中,采用 F1 分数作为绩效指标评价 3 种函数激活的性能。在使用相同数据集的情况下,Elu 函数的非线性激励作用使得模型展现出最好的性能。

3.2 FCN 训练结果分析

本研究所提方法得出以混淆矩阵为结果的模型性能评价标准。混淆矩阵是评价 CNN 模型训练结果的重要指标,用于评判分类器的优劣。由 FCN 模型训练结果绘制的混淆矩阵如图 7 所示,模型在测试集上得到较高的准确率、精度和召回率。混淆矩阵是一个 6×6 的方阵,其中,准确率位于矩阵的右下角,精度位于矩阵的最后一列,召回率位于矩阵的最后一行,每个小方框中上下 2 个数字分别代表被正确识别的概率及被错误识别的概率;其他方框中

表 1 应变数据集数量分布 个

类别	训练集	验证集	测试集	总计
正常	14 750	3 687	4 263	22 700
跳点	2 142	535	535	3 212
缺失	10 986	2 746	2 230	15 962
次小	5 496	1 374	1 374	8 244
偏移	2 168	542	144	2 854




图 6 FCN模型不同激活函数训练准确率和损失的结果比较

— ReLU准确率; - - LeakyReLU准确率; ··· ELU准确率;
— ReLU损失; - - LeakyReLU损失; ··· ELU损失

表 2 FCN 模型验证集 F1 分数的结果比较 %

类别	Relu	LeakyRelu	Elu
正常	93.7±1.4	95.8±1.0	99.0±0.3
跳点	90.6±0.9	92.4±0.7	94.1±0.2
缺失	98.8±0.6	99.0±0.4	99.2±0.3
次小	94.8±0.4	97.7±0.2	97.6±0.4
偏移	87.0±1.0	86.3±1.2	88.8±1.0

上下 2 个数字分别代表被正确识别的样本个数及概率。在最终测试阶段,利用随机选取的数据组成测试集模拟 SHM 的实际数据,最终识别率达到 98.6%,仅有 1.4%的样本被错误分类。

3.3 GoogLeNet 和 FCN 的比较

比较基于 GoogLeNet 模型与本文所提出的基于 FCN 模型的性能。2 种模型均采用相同的输入和训练方式,基于数据的可靠性,分别进行 5 次训练,选择训练效果最好的准确率和损失,如图 8 所示。表 3 给出了基于 2 种模型训练的测试精度、召回率和 F1 分数的结果。本文提出的基于 FCN 进行异常诊断的方法,在整个过程中大部分类别都获得较高的 F1 分数。该方法的总体性能优于原 GoogLeNet 模型。在训练速度上,基于 GoogLeNet 模型进行训练需要将近 3 h,测试时间需要 37 s 左右;而基于 FCN 模型仅需 2 h 就完成了训练,测试时间在 3 s 以内。对比研究充分证明了基于 FCN 进行异常数据诊断方法的优越性。

		测试集						
输出类	1	4217 49.3%	0 0.0%	0 0.0%	0 0.0%	6 0.1%	99.9%	0.1%
		2	4 0.0%	529 6.2%	9 0.1%	44 0.5%	0 0.0%	90.3%
3	0 0.0%	0 0.0%	2211 25.9%	1 0.0%	0 0.0%	100.0%	0.0%	
	4	0 0.0%	2 0.0%	10 0.1%	1329 15.6%	0 0.0%	99.1%	0.9%
5	42 0.5%	4 0.0%	0 0.0%	0 0.0%	138 1.6%	75.0%	25.0%	
	目标类	98.9%	98.9%	99.1%	96.7%	95.8%	98.6%	1.4%
		1.1%	1.1%	0.9%	3.3%	4.2%		
		1	2	3	4	5		

图 7 FCN 模型训练结果绘制的混淆矩阵




图 8 基于GoogLeNet和FCN模型训练结果的准确率和损失比较
 — GoogLeNet准确率; - - FCN准确率;
 — GoogLeNet损失; - - FCN损失

表 3 基于 GoogLeNet 和 FCN 模型训练的测试精度、召回率和 F1 分数

%

类别	GoogLeNet			FCN		
	精度	召回率	F1 分数	精度	召回率	F1 分数
正常	96.0±0.4	97.4±0.4	97.4±0.5	99.5±0.4	98.8±0.8	99.0±0.3
跳点	91.4±1.0	93.4±0.9	94.1±0.7	90.6±1.3	98.2±0.7	94.1±0.2
缺失	98.1±0.3	98.5±0.2	98.0±0.4	99.9±0.1	98.8±0.3	99.2±0.3
次小	97.0±0.3	99.0±0.2	98.1±0.4	98.7±0.4	96.7±0.2	97.6±0.4
偏移	74.0±8.4	89.0±1.5	74.2±1.3	75.5±5.7	94.2±1.2	88.8±1.0

4 结论

本文提出了一种基于全卷积神经网络(FCN)的结构健康监测(SHM)数据异常诊断方法,结论如下:

1) FCN 的主干结构选用 GoogLeNet 网络,对原网络结构做全卷积调整,减少了参数量,卷积层能捕捉到图片的空间信息。与原 GoogLeNet 模型的性能相比,本文所设计和训练的网络模型对数据异常诊断的总体准确率达到 98.6%,各类别的训练精度均有所提高,且在识别速度上更快。本文所提方法分类对象相对简单,不采用上采样层,在保证精度的同时显著减少了大量计算,大大提高了识别速度。

2) 通过 Relu、LeakyRelu、Elu 3 种不同激活函数的原理知识和应用训练,证实了 Elu 函数在模型训练过程中加入的非线性因素对模型训练的结果起到至关重要的作用,模型在 Elu 函数激活效应下的分类性

能有所提高。

本研究采用不平衡数据集,因此分类结果显示对于偏移类别的精度较低,对于平衡数据集下的模型分类性能仍有待进一步验证。

参考文献(References):

- [1] HE Z G, LI W T, SALEHI H D, et al. Integrated structural health monitoring in bridge engineering[J]. Automation in Construction, 2022, 136: 104168.
- [2] LEI X M, XIA Y, WANG A, et al. Mutual information based anomaly detection of monitoring data with attention mechanism and residual learning[J]. Mechanical Systems and Signal Processing, 2023, 182: 109607.
- [3] HOU J L, JIANG H C, WAN C F, et al. Deep learning and data augmentation based data imputation for structural health monitoring system in multi-sensor damaged state[J]. Measurement, 2022, 196: 111206.
- [4] 李惠, 周文松, 欧进萍, 等. 大型桥梁结构智能健康监测系统集成技术研究[J]. 土木工程学报, 2006(2): 46-52.
LI Hui, ZHOU Wensong, OU Jinping, et al. A study on system integration technique of intelligent monitoring systems for soundness of long-span bridges[J]. China Civil Engineering Journal, 2006(2): 46-52.
- [5] SARMADI H, KARAMODIN A. A novel anomaly detection method based on adaptive Mahalanobis-squared distance and one-class KNN rule for structural health monitoring under environmental effects[J]. Mechanical Systems and Signal Processing, 2020, 140: 106495.
- [6] ZHANG Y Q, TANG Z Y, YANG R J. Data anomaly detection for structural health monitoring by multi-view representation based on local binary patterns[J]. Measurement, 2022, 202: 111804.
- [7] 郑远攀, 李广阳, 李晔. 深度学习在图像识别中的应用研究综述[J]. 计算机工程与应用, 2019, 55(12): 20-36.
ZHENG Yuanpan, LI Guangyang, LI Ye. Survey of application of deep learning in image recognition[J]. Computer Engineering and Applications, 2019, 55(12): 20-36.
- [8] RAWAT W, WANG Z H. Deep convolutional neural networks for image classification: A comprehensive review[J]. Neural Computation, 2017, 29(9): 2352-2449.
- [9] 孙志军, 薛磊, 许阳明, 等. 深度学习研究综述[J]. 计算机应用研究, 2012, 29(8): 2806-2810.
SUN Zhijun, XUE Lei, XU Yangming, et al. A review of deep learning research[J]. Application Research of Computer, 2012, 29(8): 2806-2810.
- [10] AZIMI M, ESLAMLOU A D, PEKCAN G. Data-driven structural health monitoring and damage detection through deep learning: State-of-the-art review[J]. Sensors, 2020, 20(10): 2778.
- [11] 姜世宇, 徐菁, 任师训, 等. 基于压电阻抗和卷积神经网络的螺栓球节点健康监测[J]. 青岛理工大学学报, 2022, 44(2): 43-50.
JIANG Shiyu, XU Jing, REN Shixun, et al. Health monitoring of bolted ball nodes based on piezoelectric impedance and convolutional neural networks[J]. Journal of Qingdao University of Technology, 2022, 44(2): 43-50.
- [12] BAO Y Q, TANG Z Y, LI H, et al. Computer vision and deep learning-based data anomaly detection method for structural health monitoring[J]. Structural Health Monitoring, 2019, 18(2): 401-421.
- [13] TANG Z Y, CHEN Z C, BAO Y Q, et al. Convolutional neural network-based data anomaly detection method using multiple information for structural health monitoring[J]. Structural Control and Health Monitoring, 2019, 26(1): e2296.
- [14] WANG S, LIU C, ZHANG Y. Fully convolution network architecture for steel-beam crack detection in fast-stitching images[J]. Mechanical Systems and Signal Processing, 2022, 165: 108377.
- [15] CAO Y Z, WU Z F, SHEN C H. Estimating depth from monocular images as classification using deep fully convolutional residual networks[J]. IEEE Transactions on Circuits & Systems for Video Technology, 2018, 28(11): 3174-3182.
- [16] DUNG C V, ANH L D. Autonomous concrete crack detection using deep fully convolutional neural network[J]. Automation in Construction, 2019, 99: 52-58.
- [17] 张珂, 冯晓晗, 郭玉荣, 等. 图像分类的深度卷积神经网络模型综述[J]. 中国图象图形学报, 2021, 26(10): 2305-2325.
ZHANG Ke, FENG Xiaohan, GUO Yurong, et al. Overview of deep convolutional neural networks for image classification[J]. Journal of Image and Graphics, 2021, 26(10): 2305-2325.

(责任编辑 赵金环; 英文校审 程文华)