

DOI:10.19651/j.cnki.emt.2108017

基于FCN的轮对踏面检测技术^{*}

杨 玲^{1,2} 高军伟^{1,2}

(1. 青岛大学自动化学院 青岛 266071; 2. 山东省工业控制技术重点实验室 青岛 266071)

摘要: 传统的图像处理方法在检测轮对踏面上的磨损区域时,由于轮对表面存在的阴影以及污渍的影响,易产生误识别问题,为此提出一种基于全卷积神经网络检测踏面轮廓图以识别磨损区域的方法。首先使用CCD相机对低速运行的轮对踏面轮廓图进行采集,然后将轮廓图中存在磨损的区域进行标定制作成标签,使用FCN-32S、FCN-16S、FCN-8S模型进行训练。实验结果表明FCN-32S、FCN-16S、FCN-8S模型均能有效检测出存在较大磨损的区域,而FCN-8S模型对于点状磨损区域的检测效果明显优于FCN-32S及FCN-16S,且对于实验中设置的存在污渍干扰的区域3种模型均不存在误识别现象。最后通过MIoU值对FCN-32S、FCN-16S、FCN-8S检测效果进行评价,改变模型训练次数,MIoU值最终会停留在0.7附近,检测效果良好。

关键词: 机器视觉;全卷积神经网络;卷积层;池化层;全连接层

中图分类号: TP29 文献标识码: A 国家标准学科分类代码: 520.2060

FCN-based wheelset tread detection technology

Yang Ling^{1,2} Gao Junwei^{1,2}

(1. School of Automation, Qingdao University, Qingdao 266071, China;

2. The Shandong Province Key Laboratory of Industrial Control Technology, Qingdao 266071, China)

Abstract: When the traditional image processing method detects the wear area on the tread of the wheel, due to the influence of the shadow and stains on the surface of the wheel, it is easy to cause misidentification. Ways to identify areas of wear. First, use a CCD camera to collect the low-speed wheel tread profile map, and then calibrate the worn area in the profile map to make labels, and use FCN-32S, FCN-16S, FCN-8S models for training. The experimental results show that the FCN-32S, FCN-16S, and FCN-8S models can effectively detect areas with large wear, and the FCN-8S model is significantly better than FCN-32S and FCN-16S for detecting point wear areas. And there is no misrecognition phenomenon for the three models of the area with stain interference set in the experiment. Finally, the detection effect of FCN-32S, FCN-16S, and FCN-8S is evaluated by the MIoU value, and the number of model training is changed, the MIoU value will eventually stay near 0.7, and the detection effect is good.

Keywords: machine vision; fully convolutional neural network; convolutional layer; pooling layer; fully connected layer

0 引言

出行安全一直与人类生命健康密切相关,特别是铁路这一结构复杂、承载人数众多的交通方式。一旦出现故障,造成的生命财产损失不可估量。为此,必须关注铁路安全的方方面面,而针对轮对踏面磨损的检测正是其中重要的一环。必须对轮对踏面进行定期检测,保证踏面磨损在安全范围之内。

国内外针对轮对踏面磨损的检测方法有很多,Doroshtnasir等^[1]提出的红外热像无损检测技术已经应用

到踏面磨损区域的检测中;林颖^[2]在此基础上使用基于多尺度区域感知的盲复原算法加以改进,但这种技术难以确认是否选择热激励且对红外图像处理上存在困难。近年来国内的光电测量法发展迅速;徐志军等^[3]使用激光照射轮对踏面,通过对采集到的踏面轮廓图进行处理得到踏面数据,从而对踏面的磨损情况进行分析;冯其波等^[4]提出的利用两个激光位移传感器动态测量车轮踏面参数的方法,这些都是通过检测车轮外形参数进而得到踏面磨损情况。而随着人工智能的不断发展,基于图像处理检测踏面磨损区域的方法由于具有自我学习能力强、且能够批量检测的优

收稿日期:2021-10-07

*基金项目:山东省自然科学基金(ZR2019MF063)、山东省重点研发计划(2017GGX10115)项目资助

点日益成为研究的热点。刘成刚^[5]使用卷积神经网络对磨损区域进行检测,这种方法易受光照以及轮对表面存在的污渍影响,易误将这些存在阴影或者污渍的区域识别成存在磨损的区域。为此考虑将光电测量方法与图像处理方法相结合,使用 CCD 相机采集激光照射到轮对表面形成的踏面轮廓图,对磨损区域进行标记制作成标签,经过 FCN-32S、FCN-16S、FCN-8S 模型进行训练,检测踏面的磨损区域。由于踏面上存在的污渍不会影响踏面的光滑程度,所以当激光照射到踏面时仍会呈现出一条光滑的曲线,不会干扰模型对磨损区域的识别。此外针对磨损区域大小的不同,通过 MIOU 值,对 FCN-32S、FCN-16S、FCN-8S 模型的识别效果进行评价,验证实验的效果。

1 轮廓图获取

实验中使用到的采集装置如图 1 所示,在低速运行的轮对两侧分别放置 1 个激光源和 1 个 CCD 相机。当激光照射到轮对表面时,会在轮对上形成踏面轮廓图^[6]。若轮对表面光滑无磨损,则会形成一条完整平滑的曲线;若轮对表面存在磨损,那么形成曲线会存在明暗相交替、不连续的现象。实验所采集的轮对根据实际轮对进行等比例复制,采用铝浇筑而成。与实际轮对相比,实验室中的轮对更易产生磨损,为采集含有磨损区的轮廓图提供了便利。实验中对轮对踏面进行不同程度的破坏,得到大小深浅不相同的带有磨损区域的轮廓图。为保证实验能够有效避免污渍及光照阴影的影响,对轮对表面涂抹大小不同的黑色污渍,并在不同光照条件下对轮对踏面图进行采集。启动装置进行低速转动,并进行采集,实验共采集了 2 000 多张踏面轮廓图,图 2(a)为实验中采集到的其中一张轮廓图,图中黑色区域为针对传统图像处理方法设置的干扰。图 2(b)为轮廓图中存在磨损较严重的区域,图 2(c)为表面无磨损区域的轮廓图。

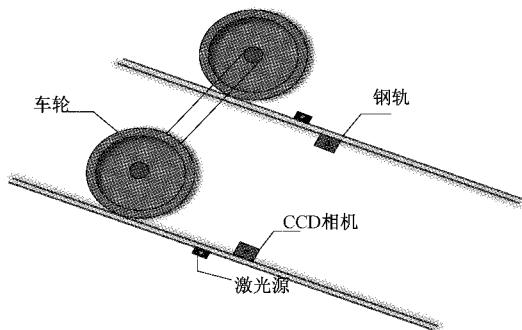


图 1 图像采集装置

2 卷积神经网络

2.1 卷积神经网络基本结构

实验中使用的 FCN-32S、FCN-16S、FCN-8S 模型均以卷积神经网络中的 VGG16 模型为基础改变而来,为此首

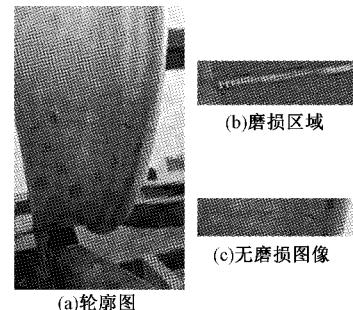


图 2 踏面轮廓对比图

先对卷积神经网络进行介绍。卷积神经网络一般由输入层、卷积层、池化层、全连接层和输出层组成^[7],基本结构如图 3 所示。实验中采集到的踏面轮廓图实际上是一个三维神经元,图像由输入层进入神经网络,经过卷积层对图像进行局部特征提取^[8],池化层对特征区域进行压缩。卷积神经网络中有多个卷积层与池化层,两者交替设置。经过卷积层与池化层处理的图像再经全连接层整合得到的具有类别区分性的局部信息,最后由输出层输出。接下来对卷积神经网络中较为重要的卷积层、池化层以及全连接层具体过程进行介绍。

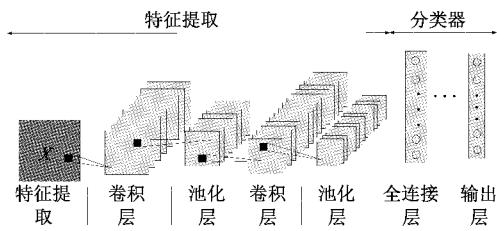


图 3 卷积神经网络基本结构

2.2 卷积层

卷积层通过卷积操作提取图像特征,如图 4 所示,输入大小为 $7 \times 7 \times 3$ 的图像,分别与卷积核 FILTER W0, FILTER W1 进行卷积操作,考虑偏置后,得到右侧的输出。初始的卷积层只能提取图像的边缘、角落等低级特征,经过多次卷积操作后才能提取到高级特征^[9]。

通过在卷积层之后连接激活函数,引入非线性因素,可以将卷积层输出的线性特征映射到非线性空间上。图 5 是几种常见的激活函数^[10]。Sigmoid 函数与 Tanh 函数为饱和非线性函数,ReLU 函数为不饱和非线性函数,在全卷积神经网络中,一般采用 ReLU 激活函数。因为相对于 Sigmoid 和 Tanh 函数,ReLU 函数计算量小,反向传播收敛速度快,还能够缓解梯度消失现象以及过拟合问题。

2.3 池化层

池化层一般位于两个卷积层之间^[11],起到防止过拟合,提升泛化能力的作用。池化层有 3 种操作方式,分别为平均池化、随机池化和最大池化,卷积神经网络中使用的是最大池化的操作方式^[12-14]。最大池化操作过程如图 6 所示,输入特征大小为 4×4 ,经大小为 2×2 ,步长为 2 的池化

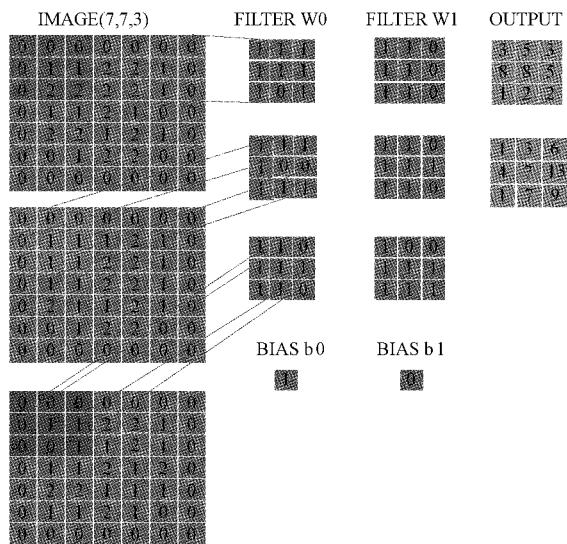


图4 卷积操作过程

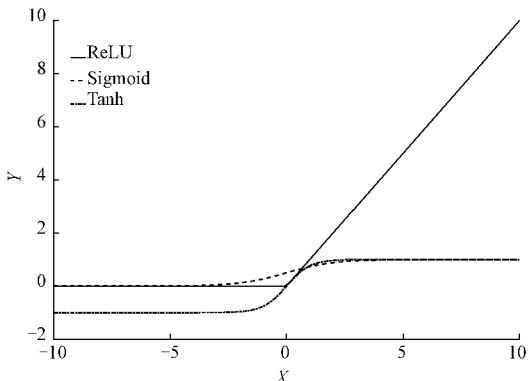


图5 激活函数

操作,提取输入特征每一部分中的最大值,得到右侧的输出特征。

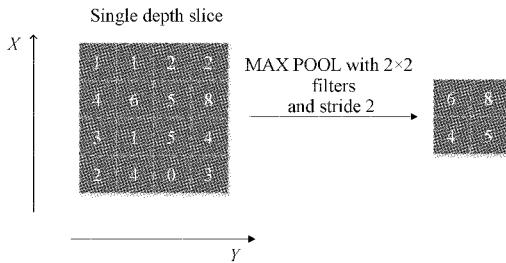


图6 池化操作过程

从池化层的操作过程可以看出池化层在保留卷积层输出特征的基础上,有效地缩小参数矩阵的尺寸,具有加快计算速度,防止过拟合,同时减少最后全连层中的参数数量的作用。

2.4 全连接层与输出层

在卷积神经网络中,经过多次卷积与池化操作后,会接若干个全连接层整合具有类别区分性的局部信息^[15]。

全连接层具体操作过程如图7所示,全连接层中的每个神经元与上一层所有神经元进行全连接,输出一维向量,整合卷积层或者池化层中具有类别区分性的局部信息,在图像处理中全连接层还起到减少位置特征对分类影响的作用。

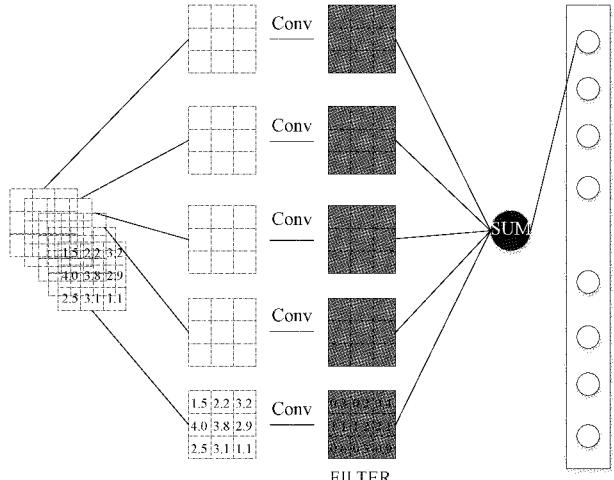


图7 全连接层操作过程

全连接层后连接 Softmax 函数,Softmax 函数公式如式(1)所示,首先将模型的预测结果转化到指数函数上,然后将转化后的结果除以所有转化后结果之和^[16]。既保证了概率的非负性,又可以将结果转化为百分比。

$$a_j^L = \frac{e^{z_j^L}}{\sum_k e^{z_k^L}} \quad (1)$$

2.5 VGG 模型

VGG16 模型是一种典型的卷积神经网络模型,包含 13 个卷积层,卷积核大小为 3×3 ,步长为 1,方式为 SAME 卷积。池化层采用最大池化,构成池化层的滤波器大小为 2×2 ,步长为 2。图 8 为 VGG16 模型的操作过程,首先进行 2 个 2 次卷积操作,然后进行 1 次池化操作,再进行 3 个 3 次卷积操作,1 个池化操作,经过 2 个全连接操作后,经 SOFTMAX 函数激活输出^[17]。相比其他卷积神经网络模型相比,VGG16 模型使用大小为 3×3 小卷积核进行连续操作代替大卷积核,可以有效减少参数量,提高模型判别能力。

3 基于FCN的擦伤区域识别

3.1 全卷积神经网络

卷积神经网络中使用的全连接层虽然具有减少位置特征对分类影响的优点,但是会破坏图像的空间结构。所以全卷积神经网络去掉了全连接层,只保留了卷积层和池化层。由于去掉了全连接层,所以与卷积神经网络相比,全卷积神经网络可以接受任意尺寸的图像输入,图像中的每个像素只提取了感受野的信息,能够减少无关背景的干扰,同时还能减少过拟合现象^[18]。

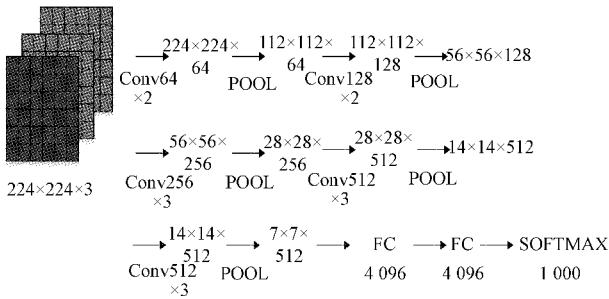


图 8 VGG16 模型

全卷积神经网络中的 FCN-32S、FCN-16S、FCN-8S 均以 VGG16 模型为基础,FCN-32S、FCN-16S、FCN-8S 模型结构如图 9 所示,FCN-32S 在 VGG16 的基础上将全连接层换成了卷积层,经过上采样将 pool5 放大 32 倍。FCN-16S 将 pool4 与 $2 \times$ pool5 进行拼接,经上采样放大 16 倍^[19]。FCN-8 则是将 pool4 与 $2 \times$ pool5 的结果进行上采样,放大两倍后与 pool3 进行拼接,经上采样后放大 8 倍。根据 FCN-32S、FCN-16S、FCN-8S 模型的操作过程可以看出,FCN-32S 只提取了第 5 层特征的信息,FCN-16S 提取了第 5 层与第 4 层特征的信息,FCN-8S 则提取第 3 层、第 4 层以及第 5 层特征的信息。所以相比 FCN-32S 和 FCN-16S,FCN-8S 得到的信息更加全面细致^[20]。

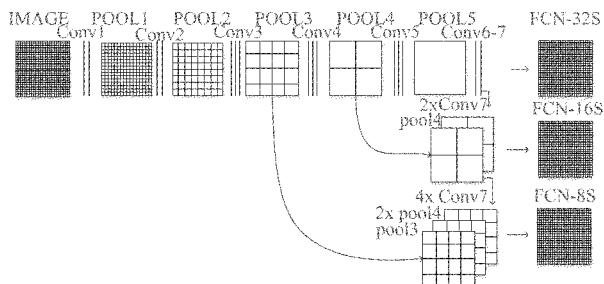


图 9 全卷积神经网络模型

3.2 数据集与训练集制作

实验中共采集到踏面轮廓图 2 000 多张,由于实验装置是以每秒 17 帧的速度自动对低速运行的轮对进行踏面轮廓的采集,所以采集到的图像既包含存在磨损区域的轮廓图,又包含无磨损区域的完好轮廓图。将这些采集到的轮廓图分为两部分,一部分是 600 张存在磨损区域的图像,作为训练集;另一部分既包含存在磨损区域的轮廓图又包含无磨损区域的轮廓图 1 400 张作为测试集。实验中的环境配置为 Windows10 操作系统,内存为 12 GB, GPU 型号为 gtx 1080ti,CPU 为 i5-7 代 4 核。训练次数为 200 次,权重衰减系数为 $2e^{-5}$,学习率为 0.001,动量为 0.9 加快学习过程。

经过 FCN-32S、FCN-16S、FCN-8S 模型训练的结果依次如图 10 所示,可以看出 FCN-8S 的训练效果明显优于 FCN-32S 和 FCN-16S。FCN-32S 和 FCN-16S 对于踏面上磨损区域较大的地方可以很好地检测出来,而对于点状磨损区域,FCN-32S

及 FCN-16S 的检测效果均不理想,而 FCN-8S 对于磨损较大区域以及点状磨损区域识别效果较好,对于存在污渍的区域,3 种模型均不存在误识别现象。交叉熵损失函数如图 11 所示,3 种模型均能快速收敛,且误差均小于 4%。

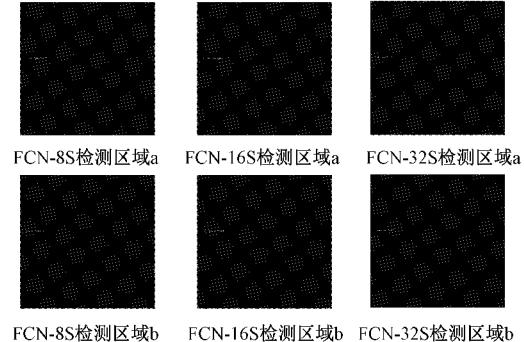


图 10 结果对比图

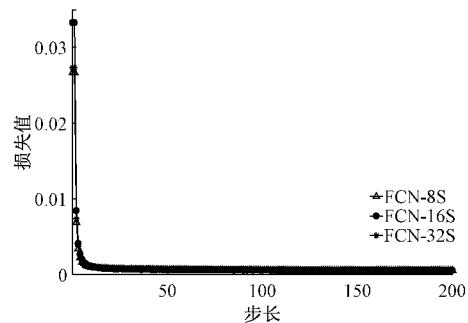


图 11 损失值函数

4 结果分析

图像分割评价有很多指标,其中最常用的是均交并比 MIoU 值。MIoU 是计算真实值与预测值两个集合的交集与并集之比^[21],是基于类进行计算的全局评价指标,具体公式如式(2)所示。

$$\text{MIoU} = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k p_{ji} - p_{ii}} \quad (2)$$

其中, $k+1$ 是类别个数 p_{ij} 表示属于类 i ,但真实值为类 j 的像素数量, p_{ii} 表示真正的数量。

本实验中的 MIoU 值如图 12 所示,经过一定次数的训

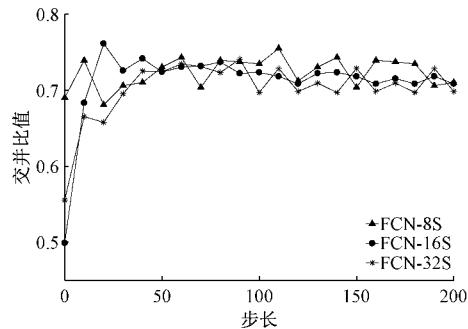


图 12 平均交并比

练 FCN-32S 与 FCN-16S 的 MIoU 值经过一定的增长后趋于稳定,保持在 0.7 附近,而 FCN-8S 的 MIoU 值则一直保持平稳,多次训练后保持在 0.73 附近波动,效果与 FCN-32S 及 FCN-16S 相比更好。

5 结 论

针对传统图像检测方法检测存在磨损区域的踏面时易受环境光照等因素的影响,本文提出了基于全卷积神经网络提取磨损区域的方法。实验中使用激光照射到轮对踏面上,得到踏面轮廓图,然后将磨损的区域标记出来,制作成标签,经过 FCN-32S、FCN-16S 以及 FCN-8S 模型进行训练。由实验可知,全卷积神经网络在光线变化以及踏面本身存在颜色变化时均能有效检测出存在磨损的区域。其中 FCN-32S、FCN-16S 能检测出踏面磨损较严重的区域,而对于磨损不明显的区域检测效果较弱。而 FCN-8S 不仅能够检测出存在严重磨损的区域,而且对于轻微磨损也具有很好的检测效果。最后使用均交并比 MIoU 值对检测结果进行评价,结果表明 FCN-32S 与 FCN-16S 的 MIoU 值经过一定训练后增长趋于稳定,保持在 0.7 附近,而 FCN-8S 的 MIoU 值则一直保持在 0.73 附近。实验结果表明基于全卷积神经网络检测踏面轮廓图可以有效检测出踏面磨损区域,且 FCN-8S 的检测效果优于 FCN-32S 及 FCN-16S。

参考文献

- [1] DOROSHTNASIR M, WORZEWSKI T, KRANKENHAGEN R, et al. On-site inspection of potential defects in wind turbine rotor blades with thermography [J]. Wind Energy, 2016, 19(8): 1407-1422.
- [2] 林颖. 基于运动模糊红外图像下的铁路货车轮对踏面检测[D]. 北京:北京交通大学, 2021.
- [3] 徐志军, 陈建政. 基于图像处理和 Hough 变换的轮对踏面轮廓检测方法[J]. 电子测量技术, 2017, 40(6): 117-121, 131.
- [4] 冯其波, 张志峰, 陈士谦, 等. 一种激光位移传感器动态测量列车车轮直径的新方法[J]. 中国激光, 2008(7): 1059-1062.
- [5] 刘成刚. 基于图像处理的列车轮对踏面缺陷分类识别研[D]. 兰州:兰州交通大学, 2021.
- [6] 杨玲, 高军伟. 基于机器视觉的轮对踏面检测技术[J]. 自动化与仪表, 2021, 36(8): 43-46, 75.
- [7] 梁盛德, 王寻, 梁金福. 基于卷积神经网络和心电 QRS 波群的身份识别[J]. 电子测量与仪器学报, 2020,
- [8] 杨真真, 匡楠, 范露, 等. 基于卷积神经网络的图像分类算法综述[J]. 信号处理, 2018, 34(12): 1474-1489.
- [9] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.
- [10] 李旭冬, 叶茂, 李涛. 基于卷积神经网络的目标检测研究综述[J]. 计算机应用研究, 2017, 34(10): 2881-2886, 2891.
- [11] 郭鹏, 肖秦琨, 赵一丹. 基于深度图像的手势识别研究[J]. 国外电子测量技术, 2019, 38(10): 6-12.
- [12] 张小丹, 陈媛媛. 基于卷积神经网络的近红外光谱模型迁移研究[J]. 国外电子测量技术, 2021, 40(7): 100-104.
- [13] 施泽浩, 赵启军. 基于全卷积网络的目标检测算法[J]. 计算机技术与发展, 2018, 28(5): 55-58.
- [14] 翁飘, 陆彦辉, 齐宪标, 等. 基于改进的全卷积神经网络的路面裂缝分割技术[J]. 计算机工程与应用, 2019, 55(16): 235-239, 245.
- [15] 薛东杰, 唐麒淳, 王傲, 等. 基于 FCN 的岩石混凝土裂隙几何智能识别[J]. 岩石力学与工程学报, 2019, 38(S2): 3393-3403.
- [16] 赵宇凯, 徐高威, 刘敏. 基于 VGG16 迁移学习的轴承故障诊断方法[J]. 航天器环境工程, 2020, 37(5): 446-451.
- [17] 卢宏涛, 张秦川. 深度卷积神经网络在计算机视觉中的应用研究综述[J]. 数据采集与处理, 2016, 31(1): 1-17.
- [18] 张永帅, 杨国威, 王琦琦, 等. 基于全卷积神经网络的焊缝特征提取[J]. 中国激光, 2019, 46(3): 36-43.
- [19] 吴韵清, 吴鹏, 陈北京, 等. 基于残差全卷积网络的图像拼接定位算法[J]. 应用科学学报, 2019, 37(5): 651-662.
- [20] 王森, 伍星, 张印辉, 等. 基于全卷积神经网络和结构化森林的结构体裂纹分割方法[J]. 仪器仪表学报, 2020, 41(8): 170-179.
- [21] 李梦怡, 朱定局. 基于全卷积网络的图像语义分割方法综述[J]. 计算机系统应用, 2021, 30(9): 41-52.

作者简介

杨玲,硕士研究生,主要研究方向为智能系统与智能控制。

E-mail: yangling2956@163.com

高军伟,博士,教授,主要研究方向为领域智能系统与智能控制。

E-mail: qdgao163@163.com