

DOI:10.19651/j.cnki.emt.2210546

基于 CA-ResNet50 的轮胎激光散斑图的分类研究*

刘韵婷^{1,2} 葛忠文¹ 郭辉²

(1. 沈阳理工大学 沈阳 110000; 2. 沈阳工业大学体育装备产业技术学院 沈阳 110870)

摘要: 针对轮胎激光散斑图识别精度低的问题,本文提出了一种新的轮胎激光散斑图分类网络(CA-ResNet50)。首先选用 ResNet50 为基础的残差网络,改变传统 ResNet50 网络模型中的残差块结构,最大程度发挥批标准化的作用;再引入轻量级的卷积注意力模块,增强网络模型对轮胎缺陷的特征提取能力;然后,用 LeakyRelu 激活函数代替 Relu 激活函数,解决神经元的“失活”问题;最后,对训练数据集进行扩展,以克服训练中数据量不足和网络模型拟合过度的问题。将本文中提出的 CA-ResNet50 与当前常用的分类网络模型在相同的数据集上进行对比,实验结果证明本文所提网络模型对轮胎激光散斑图的测试精度高于其他网络,识别精度可达到 99.7%。

关键词: 轮胎激光散斑图;图像识别;迁移学习;残差网络

中图分类号: TP2 **文献标识码:** A **国家标准学科分类代码:** 510

Classification of tyre laser scattergrams based on improved residual networks

Liu Yunting^{1,2} Ge Zhongwen¹ Guo Hui²

(1. Shenyang Ligong University, Shenyang 110000, China; 2. Sports Equipment Industry Technology Research Institute, Shenyang University of Technology, Shenyang 110870, China)

Abstract: To address the problem of low accuracy of tire laser scattergram recognition, this paper proposes a new classification network for tire laser scattergram (CA-ResNet50). Firstly, ResNet50-based residual network is selected to change the residual block structure in the traditional ResNet50 network model to maximize the role of batch normalization. Then, a lightweight convolutional attention module is introduced to enhance the feature extraction ability of the network model for tire defects. Next, LeakyRelu activation function is used instead of the Relu activation function to solve the neuronal deactivation problems. Finally, the training data set is extended to overcome the problems of insufficient data volume and overfitting of the network model in training. The CA-ResNet50 proposed in this paper is compared with the current commonly used classification network models on the same dataset, and the experimental results prove that the testing accuracy of the proposed network model in this paper is higher than other networks for tire laser scatter maps, and the recognition accuracy can reach 99.7%.

Keywords: tyre laser scattergrams; image recognition; migration learning; residual networks

0 引言

目前的轮胎内部缺陷检测,通常使用 X 光机对轮胎进行 X 光成像或使用轮胎激光散斑检测仪形成灰度激光散斑图,然后对获取到的图像进行肉眼检测。然而,肉眼检测的检测效率低,准确率低,并且对检测人员的疲劳非常敏感。如何高效、准确的对获取到的轮胎图像进行自动缺陷检测成为目前轮胎生产行业亟待解决的关键技术问题。

近年来,自动视觉检测方法越来越受到研究人员和工

业界的重点关注。Guo 等^[1]利用局部核回归描述符推导空间纹理特征,通过加权纹理的不相似性检测缺陷。Wang 等^[2]将全卷积网络(FCN)引入轮胎缺陷检测项目,证明了全卷积网络可以直接分割缺陷,并且对侧壁和胎面图像都有效。崔雪红等^[3-4]在通过将几个单个 CNN 组合成一个多对比卷积网络(MCCNN)^[3-4]来分类轮胎缺陷,该网络提高了各类缺陷的识别率。Xiang 等^[5]提供了一种基于字典表示的轮胎检测方案,该方法从轮胎图像中学习无缺陷的字典。Zhang 等^[6]将小波变换引入到轮胎缺陷检测任务中,

收稿日期:2022-07-02

* 基金项目:国家重点研发计划(19YJC890012)、辽宁省教育厅项目(LJGD2020019)、国家重点研发计划(2017YFC082100-2)项目资助

小波变换在一维信号中表现出良好的性能。刘韵婷等^[7]通过使用双线性插值算法来提高轮胎异常检测的准确率。吴则举等^[8]将 FASTER-RCNN 的算法引入轮胎缺陷检测中,提高了轮胎各类缺陷的测试精度。Sa'idah 等^[9]采用基于 GoogleNet 架构的卷积神经网络方法检测轮胎缺陷,他们对轮胎缺陷识别准确率达到 92%。Sedaghat 等^[10]通过一种基于高滤波和 LBP 的图像分析和学习处理策略,成功将轮胎缺陷定位精度达到 98%,缺陷检测精度达到 97%。Saleh 等^[11]采用两阶段的方法准确的将轮胎内部缺陷气泡成功识别出来。两阶段方法为:首先对图像进行纹理特征提取;第二阶段采用 MLP、RF 和 Gradient Boosting 分类器对轮胎剪切图中的气泡进行识别。

上述神经网络提高了轮胎缺陷检测的效果,但仍存在一些问题。首先,大多数研究人员研究轮胎 X 光射线缺陷图像,而对轮胎激光散斑缺陷图像的研究较少。轮胎激光散斑图由轮胎激光散斑检测仪^[12]产生,轮胎激光散斑缺陷图像的对比度较低,缺陷目标更接近背景。其次,一些网络

包括图像分割。对于工业生产,不需要对缺陷进行像素级分割,而只需要对缺陷进行精确检测。

为了提高轮胎激光散斑图像中轮胎内部缺陷的分类精度和识别精度,本文提出了一种新的基于 CA-ResNet50 的轮胎激光散斑图像的分类方法。该方法结合数据扩充与改进的 ResNet50^[13]网络模型在图像数据集 ImageNet 上进行迁移学习,使模型更加拟合轮胎缺陷气泡图像的特性。实验证明,该算法可以提高轮胎内部缺陷气泡的识别率。

1 CA-ResNet50 网络模型

本文提出的 CA-ResNet50 网络模型基于传统 ResNet50 网络模型,改变每个 Bottleneck 块的内部结构,并且在 ResNet50 的首个卷积层和末尾的卷积层引入轻量级的卷积注意力模块,将传统网络模型中的 Relu 激活函数改为 Leakyrelu 激活函数,CA-ResNet50 的结构如图 1 所示。

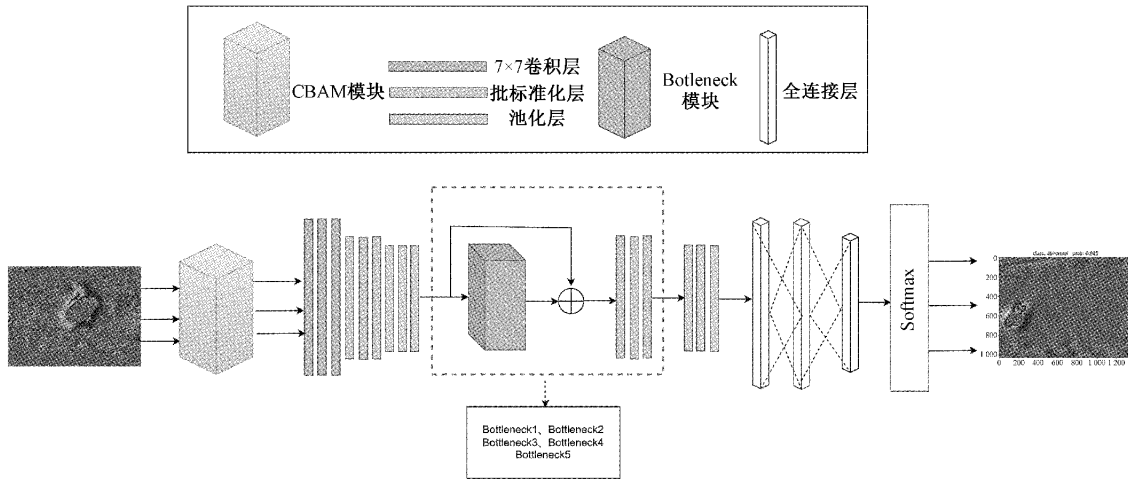


图 1 CA-ResNet50 改的网络结构图

1.1 激活函数 LeakyRelu

传统 ResNet50 网络模型中使用的是非饱和激活函数——Relu 激活函数,但是只有保证神经元的输入为正且不能为 0,Relu 激活函数才能发挥作用。一旦神经元的输入小于等于 0 时,这部分信息会丢失,Relu 激活函数无法发挥作用,此时神经元就处于“失活”的状态。本文采用 LeakyRelu^[14] 激活函数解决神经元的“失活”问题。LeakyRelu 激活函数的公式如下:

$$\text{LeakyRelu}(x) = \begin{cases} x, & x > 0 \\ \alpha x, & x \leq 0 \end{cases} \quad (1)$$

其中,α 为极小值。LeakyRelu 激活函数包含了 Relu 函数的特点——当神经元的输入为正数时发挥激活作用,同时神经元的输入在负半轴上时,也能正常发挥激活作用使梯度正常传播。

1.2 残差块的调整

在训练深度学习网络模型时,前面层参数的变化会导致后面每层输入分布的不同。较低的学习率和谨慎的参数初始化能克服上述问题,但这带来的后果就是网络模型训练速度降低。批标准化(batch normalization, BN)^[15]的作用就是令每一层输入数据分布划分在(0~1)范围内,对参数的初始化较随意,允许深度学习网络模型使用更大的学习率,并在某些情况下解决训练模型崩溃的问题和缩短网络模型的训练时间。

批标准化实现公式如下:

$$\hat{x}_i = \frac{x_i - \mu}{\sqrt{\sigma^2 + \epsilon}} \quad (2)$$

式中: x_i 为输入数据,μ 为均值,σ 为方差,ε 是一个很小的常数。

改进前的残差块结构如图2所示,样本先经过卷积层再经过BN和激活函数,这样以来样本经过BN层时的输入分布发生变化,造成部分特征信息缺失。ResNet网络模型无法学到足够多的特征信息以至于ResNet网络模型的预测能力下降。为了解决上述问题和不改变残差块结构中的恒等映射关系,将残差块的结构更改为如图3所示,样本先经过BN层和激活函数,然后经过卷积层。这样的结构调整能够保证后面层的输入数据分布不变,使ResNet网络模型学习到较多的特征信息提高网络模型的预测能力,同时也能够充分发挥BN的作用。

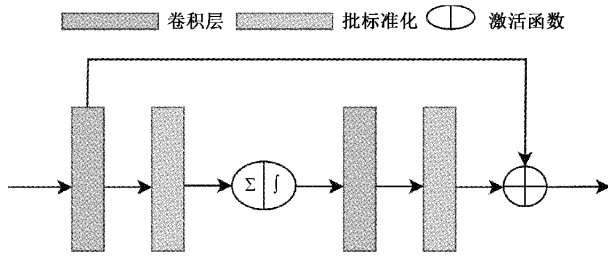


图2 传统残差块图




图3 改进后的残差块图

通过对比实验结果得出改进后的残差网络的收敛速度更快且鲁棒性更好,分类准确率比原网络提高了1.7%,如表1所示。

表1 不同技巧下的消融实验

技巧	模型	测试集准确率/%	测试集损失
A	ResNet50	97.2	0.059
B	A+LeakyRelu	98.2	0.047
C	B+残差块调整	98.9	0.040
D	C+CBAM	99.7	0.038

1.3 轻量级的卷积注意力模块

考虑到网络模型能够更好的提取检测目标的特征和准确定位缺陷,本文引入轻量级的卷积注意力模块(convolutional block attention module, CBAM)^[16],注意力模块可以提高模型的学习能力:专注于学习有意义的特征信息而摒弃没有意义的特征信息。CBAM包含两个子模块,分别为通道注意力模块(channel attention module, CAM)和空间注意力模块(spatial attention module, SAM)。CAM模块可以关注输入样本中有意义的信息即为为什么将轮胎激光

散斑图分为正常和异常, SAM关注的是将检测目标在样本中的位置即轮胎缺陷部位在样本图中的具体位置。注意力模块的加入大大提高了网络模型对轮胎缺陷特征提取的能力。CBAM的结构图如图4所示。




图4 CBAM模块

2 数据集的制作

为解决由于数据量不足导致的过拟合问题,本文需对轮胎激光散斑样本图进行一定的扩充,将原数据集2000张扩充到16000张,标签信息分为正常(normal)和异常(abnormal)。部分轮胎激光散斑图像如图5所示。具体的扩充方法如表2所示。

表2 数据扩充方法

方法名称	具体方法
色彩变换	调整图片的饱和度,亮度以及对比度
尺度变换	最近插值和双线性插值方法
对比度变换	直方图均衡化
高斯噪声	偏移量为0.1,标准差为0.2
旋转处理	以顺时针方向45°旋转

部分图像通过扩充后得到的新图像如图5所示。




图5 部分样本图像及扩充后的新图像

3 实验

3.1 实验配置

本文实验环境为:处理器为AMD Ryzen 7 3700U with

Radeon Vega Mobile Gfx 2.30 GHz 和 NVIDIA GeForce RTX 2080Ti 显卡, Linuxc 操作系统, 以 Pytorch1.10.0 为深度学习框架, Python 版本为 3.7.0。采用准确率 (Accuracy) 作为模型的评价指标, 识别正确的样本个数 (I_r) 与样本总数 (I_{all}) 的比就是准确率, 表达式:

$$Accuracy = \frac{I_r}{I_{all}} \quad (3)$$

Accuracy 值越大, 说明模型的预测能力越强, 泛化能力越好。

3.2 数据扩充对实验结果的影响

有无数据扩充的对比实验测试结果如表 3 所示。

表 3 有无经过数据集扩充的实验结果

技巧	训练集	训练集	测试集	测试集
	准确率/%	损失	准确率/%	损失
未扩充	96.5	0.010	97.2	0.120
扩充	97.8	0.009	99.7	0.038

由表 3 可知, 经过数据扩充处理后, 模型在准确率上有所提高, 在损失值上有所降低。训练集准确率提高了 1.3%, 测试集准确率提高了 2.5%, 训练集损失值降低了 0.001, 测试集上损失值降低了 0.082。这证明经过数据扩充处理, 数据量变大和样本集特征增多, 增强了模型的泛化能力。由图 6 可知, 经过数据扩充处理后损失值曲线更平滑, 这证明网络模型的学习能力增强了并且鲁棒性更好了。




图 6 有无数据增强的实验结果曲线

3.3 迁移学习对实验结果的影响

因为深度网络模型获取图像的初步特征是相似的, 所以本文中应用迁移学习^[17]的方式为特征迁移。通过迁移学习将 CA-ResNet50 网络模型在 ImageNet 数据集上预训练出一个提取图像初步特征的模型, 在训练过程中冻结改进 ResNet50 的全连接层, 然后将预训练的模型在轮胎激光散斑图像数据集上训练。通过一组有无迁移学习的对

比实验, 证实了迁移学习的优势, 实验结果如图 7 所示。由图 7 中可知在结合迁移学习的条件下, 网络模型不但可以提高识别率和测试精度, 同时收敛速度也有明显提高。




图 7 有无迁移学习的实验结果曲线

3.4 消融实验

为了验证提出的每个技巧的有效性, 本文以增量方式逐个增加每个技巧。在相同数据集的条件下对不同技巧下的网络模型进行实验, 测试结果如表 1 所示。

从 A 到 B 的过程中, 由表 1 可知改变激活函数使用 LeakyRelu 激活函数可以使 ResNet50 网络模型准确率提升了 1.0%, 损失值降低了 0.012。这是因为 LeakyRelu 激活函数可以保证神经元输入数据为负的情况下, 依然能够发挥激活函数的作用, 增强模型的鲁棒性。

从 B 到 C 的过程中, 在 B 的基础上改变残差块结构的技巧使 ResNet50 网络模型准确率提高了 1.7%, 损失值降低了 0.019。这是因为改变网络结构后发挥了批标准化作用, 降低了过拟合问题, 增强了模型的收敛速度。

从 C 到 D 的过程中, 在 C 的基础上引入 CBAM 模块, 此技巧可以使网络模型准确率提高了 2.5%, 损失值降低了 0.021。这是因为 CBAM 模块对轮胎缺陷特征部位和轮胎缺陷部位的位置感性兴趣, 帮助 ResNet50 网络模型提升对轮胎缺陷特征的表达能力及轮胎缺陷部位的准确定位。

消融实验的结果证明本文中提出的改进技巧均能提高网络的识别精度, 并且将 3 种方法结合起来构建的新网络 CA-ResNet50 网络模型的性能更突出。

为了为验证引入 CBAM 模块能够过增强 ResNet50 对轮胎缺陷特征提取的能力, 本文采用 Grand-CAM 方法分别对 layer4, sa1, ca1 层可视化, 可视化结果如图 8 所示, 由图 8 所知引入的通道注意力子模块对轮胎缺陷特征部位感兴趣, 并且空间注意力子模块对轮胎缺陷部位的位置感兴趣。两者综合起来的 CBAM 模块可以帮助 ResNet50 网络模型提升对轮胎缺陷特征的表达能力及轮胎缺陷部位的准确定位。




图8 部分可视化图

3.5 不同网络模型对实验结果的影响

为了验证本文提出改进网络模型的优越性,在相同的数据集下对当下常用的分类网络模型进行了实验。实验结果如表4所示。由表4可以看出,本文提出的网络模型在测试集准确率上排名第一为99.7%,但在训练时间和训练参数上稍逊于其他网络。从图9和表4可知在ResNet网络模型体系网络模型中,可以清楚看到ResNet50网络

表4 不同网络模型的对比实验结果

模型	测试集 准确率/%	训练 时间/min	模型 训练参数
AlxNet	94.2	60.81	57.02×10^6
GoogleNet	93.6	68.76	5.60×10^6
VGG16	94.8	105.85	134.28×10^6
VGG19	94.0	180.53	139.59×10^6
ResNet-18	95.8	63.64	11.80×10^6
ResNet50	97.5	91.25	23.52×10^6
ResNet-101	95.5	120.86	42.51×10^6
本文方法	99.7	87.55	23.50×10^6

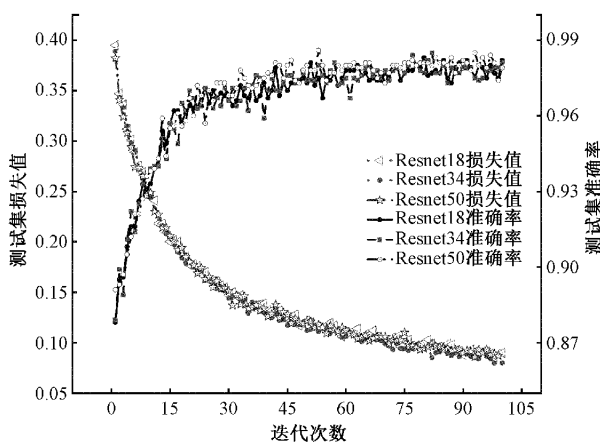


图9 不同深度的Resnet网络实验结果

模型在准确率上要高于层数较浅的ResNet-18网络模型和层数较深的ResNet-101网络模型,虽然在训练时间和训练参数上要稍高于其他两个网络模型,但是综合考虑平衡训练时间和训练参数,本文以ResNet50网络模型为基础框架。另外从表4可以看出,ResNet体系网络模型的性能在轮胎激光散斑图像识别中要比AlxNet网络模型^[18]、GoogleNet网络模型^[19]、VGG网络模型^[20]体系更好,这证明ResNet系列网络模型更适合于本文的研究。比较本文提出的网络模型与传统ResNet50网络模型,由表4可以清晰的看出CA-ResNet50网络模型在准确率上提升了2.2%,训练时间也有所下降,这证明CA-ResNet50网络模型更有利于轮胎激光散斑图像的识别。由图10可知,CA-ResNet50网络模型较其他分类网络拟合性更好,收敛速度更快。

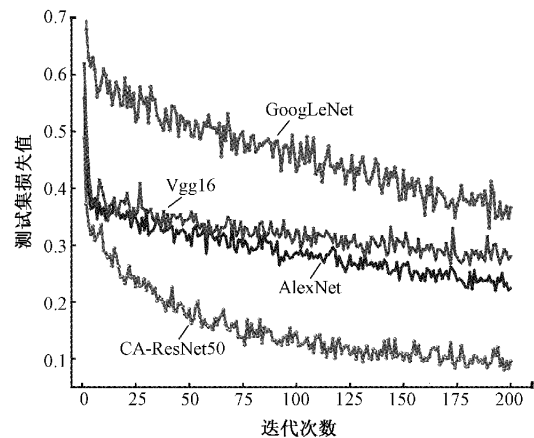


图10 不同网络模型的测试集损失值曲线图

4 结 论

为了进一步提升对轮胎激光散斑图轮胎气泡缺陷的识别率,本文提出一种基于CA-ResNet50模型的轮胎激光散斑图像轮胎气泡缺陷的识别方法。首先,对轮胎原始数据集进行扩充,解决因数据量少而产生的过拟合问题,然后将优化模型结合迁移学习对轮胎激光散斑数据集进行训练及分类,迁移学习可以大大减少模型的训练时间并提高模型的测试精度和识别率。将检测结果与当前常用的分类网络模型的检测结果进行比较,对比结果表明,CA-ResNet50网络模型具有较高的分类识别精度和良好的泛化性,对轮胎激光散斑图中轮胎气泡缺陷的识别率可达到99.7%,验证了CA-ResNet50网络模型的可行性。

参考文献

[1] GUO Q, ZHANG C, LIU H, et al. Defect detection in tire X-Ray images using weighted texture dissimilarity[J]. Journal of Sensors, 2016, 10(5): 1-12.
 [2] WANG R, GUO Q, LU S, et al. Tire defect

- detection U-sing fully convolutional network[J]. IEEE Access, 2019, 7(12): 43502-43510.
- [3] 崔雪红, 刘云, 王传旭, 等. 多路卷积神经网络的轮胎缺陷图像分类[J]. 计算机工程与设计, 2018, 39(3): 873-879.
- [4] 崔雪红, 刘云, 王传旭, 等. 基于卷积神经网络的轮胎缺陷 X 光图像分类[J]. 电子测量技术, 2017, 40(5): 168-173.
- [5] XIANG Y, ZHANG Y, QING G. A dictionary-based method for tire defect detection [C]. 2014 IEEE International Conference on Information and Automation(ICIA), IEEE, 2014: 519-523.
- [6] ZHANG Y, LEFEBVRE D, LI Q. Automatic detection of defects in tire radiographic images[J]. IEEE Transactions on Automation Science and Engineering, 2015, 14(3): 1378-1386.
- [7] 刘韵婷, 于清淞, 李绅科, 等. 基于深度学习的多模型融合图像智能检测方法研究[J]. 电子测量技术, 2021, 44(20): 168-174.
- [8] 吴则举, 焦翠娟, 陈亮. 基于 Faster-R-CNN 算法的轮胎缺陷检测方法[J]. 计算机应用, 2021, 41(7): 1939-1946.
- [9] SA'IDAH S, FANY A, SUPARTA I. Convolutional neural network googlenet architecture for detecting the defect tire [C]. 2022 International Conference on Computer Science and Software Engineering(CSASE), IEEE, 2022: 331-336.
- [10] SEDAGHAT Y, PARHIZGAR N, KESHAVARZ A. Automatic defects detection using neighborhood windows features in tire X-ray images [J]. International Journal of Nonlinear Analysis and Applications, 2021, 12(20): 2493-2508.
- [11] SALEH N A A, KONYAR M Z, KAPLAN K, et al. Detection of air bubbles from tire shearography images[C]. 2022 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA), IEEE, 2022: 1-4.
- [12] 任立国. 工程胎散斑机的研发与设计[J]. 橡塑技术与装备, 2011, 37(6): 37-40.
- [13] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [14] XU B, WANG N, CHEN T, et al. Empirical evaluation of rectified activations in convolutional network[J]. Arxiv Preprint, 2015, ArXiv:1505.00853.
- [15] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]. International Conference on Machine Learning, PMLR, 2015: 448-456.
- [16] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3-19.
- [17] YING W, ZHANG Y, HUANG J, et al. Transfer learning via learning to transfer [C]. International Conference on Machine Learning, PMLR, 2018: 5085-5094.
- [18] KRIZHEVSKY A, SUTSKEVER I, HINTON G. Imagenet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [19] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. Arxiv Preprint, 2014, ArXiv: 1409.1556.
- [20] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1-9.

作者简介

刘韵婷, 副教授, 主要研究方向为人工智能, 传感器网络, 数据分析等。

E-mail: liuyunting0224@163.com

葛忠文, 硕士, 主要研究方向为异常检测。

E-mail: 1255060886@qq.com

郭辉(通信作者), 副教授, 主要研究方向为数据分析、装备工程等。

E-mail: guoh739@163.com