



基于卷积神经网络的光学元件表面缺陷图像分类

侯劲尧 刘卫国 周顺 高爱华 葛少博 肖相国

Image classification of optical element surface defects based on convolutional neural network

HOU Jinyao, LIU Weiguo, ZHOU Shun, GAO Aihua, GE Shaobo, XIAO Xiangguo

引用本文:

侯劲尧, 刘卫国, 周顺, 等. 基于卷积神经网络的光学元件表面缺陷图像分类[J]. 应用光学, 2023, 44(3): 677–683. DOI: 10.5768/JAO202344.0305003

HOU Jinyao, LIU Weiguo, ZHOU Shun, et al. Image classification of optical element surface defects based on convolutional neural network[J]. *Journal of Applied Optics*, 2023, 44(3): 677–683. DOI: 10.5768/JAO202344.0305003

在线阅读 View online: <https://doi.org/10.5768/JAO202344.0305003>

您可能感兴趣的其他文章

Articles you may be interested in

基于卷积神经网络的胚胎活性精准检测方法研究

Research on accurate detection method of egg embryo activity based on convolutional neural network

应用光学. 2021, 42(2): 268–275 <https://doi.org/10.5768/JAO202142.0202003>

基于时空双流卷积神经网络的红外行为识别

Infrared behavior recognition based on spatio-temporal two-stream convolutional neural networks

应用光学. 2018, 39(5): 743–750 <https://doi.org/10.5768/JAO201839.0506002>

基于深度神经网络的太阳能电池组件缺陷检测算法研究

Research on detection algorithm of solar cell component defects based on deep neural network

应用光学. 2020, 41(2): 327–336 <https://doi.org/10.5768/JAO202041.0202006>

基于小波变换与卷积神经网络的图像去噪算法

Image denoising algorithm based on wavelet transform and convolutional neural network

应用光学. 2020, 41(2): 288–295 <https://doi.org/10.5768/JAO202041.0202001>

一种基于2D-CNN的激光超声表面缺陷检测方法

Laser ultrasonic surface defects detection method based on 2D-CNN

应用光学. 2021, 42(1): 149–156 <https://doi.org/10.5768/JAO202142.0107002>

基于全卷积神经网络的图像去雾算法

Image defogging algorithm combined with full convolution neural network

应用光学. 2019, 40(4): 596–602 <https://doi.org/10.5768/JAO201940.0402003>



关注微信公众号, 获得更多资讯信息

文章编号:1002-2082 (2023) 03-0677-07

基于卷积神经网络的光学元件表面缺陷图像分类

侯劲尧¹, 刘卫国¹, 周顺¹, 高爱华¹, 葛少博¹, 肖相国²

(1. 西安工业大学 光电工程学院, 陕西 西安 710021; 2. 西安应用光学研究所, 陕西 西安 710065)

摘要: 光学元件的表面疵病, 即表面缺陷, 其形状的大小会直接影响光学系统的性能, 在对表面缺陷进行分类时, 所面对的很多表面缺陷的形状都是不规则的, 依靠普通的模式识别技术, 分类很难达到预期的效果。为解决精密光学元件表面缺陷分类方法中精度低、耗时长的问题, 提出了基于卷积神经网络的精密光学元件表面缺陷分类方法。采用散射法获取表面缺陷图像, 分析其成像特点, 通过对图像进行旋转, 镜像扩增了数据集, 加强了网络的训练能力。使用 AC 训练网络模型, 在不增加额外计算量的同时加强了网络的特征获取力。通过 Softmax 分类器, 将精密光学元件表面缺陷分为划痕、麻点及噪点 3 类。实验结果表明, 所使用的模型对缺陷分类精度超过 99.05%。

关键词: 光学元件; 表面缺陷; 卷积神经网络; 计算机视觉

中图分类号: TN206; TP751

文献标志码: A

DOI: 10.5768/JAO202344.0305003

Image classification of optical element surface defects based on convolutional neural network

HOU Jinyao¹, LIU Weiguo¹, ZHOU Shun¹, GAO Aihua¹, GE Shaobo¹, XIAO Xiangguo²

(1. College of Photoelectric Engineering, Xi'an Technological University, Xi'an 710021, China; 2. Xi'an Institute of Applied Optics, Xi'an 710065, China)

Abstract: The surface defects of optical elements, namely surface defects, will directly affect the performance of the optical system. In the classification of surface defects, the shapes of many surface defects are irregular, so it is difficult to achieve the expected effect by relying on normal pattern recognition technology. To overcome the low precision and long time consuming in classification of surface defects of precision optical elements, a classification method of surface defects based on convolutional neural network was proposed. Firstly, the surface defect image was obtained by scattering method to analyze its imaging characteristics, and the training ability of the network was strengthened by rotating the image and mirroring the amplified dataset. Furthermore, the AC training network model was used to strengthen the feature acquisition ability of the network without increasing the extra calculation. Finally, the Softmax classifier was used to classify the surface defects into scratch, pitting and noise. The experimental results show that the defect classification accuracy of the used model is more than 99.05%.

Key words: optical elements; surface defects; convolutional neural network; computer vision

引言

表面缺陷是影响光学系统质量的重要因素之一^[1]。传统的人工目视检测方法易受到人工经验和主观因素的影响, 导致测试结果误差较大, 无法

满足现行检测要求和自动生产线的在线生产要求。机器视觉检测具有自动化程度高、识别率高^[2]和非接触式测量等优点, 逐渐成为主流表面缺陷检测的方法和发展趋势。

收稿日期: 2022-05-30; 修回日期: 2022-11-14

基金项目: 基金项目: 陕西省科技厅重点研发项目资助 (2019GY-063)

作者简介: 侯劲尧 (1995—), 男, 博士研究生, 主要从事光电检测和图像处理技术研究。E-mail: 894608824@qq.com

通信作者: 刘卫国 (1964—), 男, 教授, 博士生导师, 主要从事光电子技术、电子材料技术研究。E-mail: wgliu@163.com

目前已经有大多成熟的算法可以有效完成对表面缺陷图像的去噪和分割处理,而对于表面缺陷的分类,最常见的是利用表面缺陷的散射特性用肉眼进行判定的目测法,但使用此法效率不高,易受人为因素影响,误判率较高^[3-4]。近年来,随着以卷积神经网络(convolutional neural network, CNN)为代表的深度学习模型在诸多计算机视觉(computer vision, CV)领域成功应用,例如人脸识别、场景文字检测、目标跟踪和自动驾驶等,不少基于深度学习的缺陷检测方法也广泛应用在各种工业场景中^[5-6]。如通过散射成像系统,利用形状因子将表面缺陷分为划痕、麻点、噪点 3 类,识别精度高,但识别速度很慢^[7]。或者通过 BP 神经网络实现对划痕和麻点的分类,但由于表面缺陷的随机性,整体数据的识别率不高^[8],通过神经网络将光学元件表面缺陷分为圆形、方形和条形轮廓,分类的情况较模糊^[9]。

本文提出了基于深度学习的光学元件表面缺陷分类方法。首先利用散射法获取表面缺陷图像并通过旋转、镜像等方式扩增表面缺陷的数据集,接着利用深度学习技术中的卷积神经网络对光学原件表面图像特征图进行训练与学习,构建高精度分类器识别光学元件表面缺陷特征,在保障精度的前提下,提升分类算法的效率,最终将表面缺陷分为划痕、麻点和噪点 3 类。

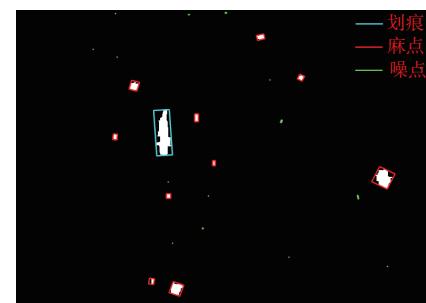
1 表面缺陷检测模型

表面缺陷主要指麻点、擦痕、开口气泡、破点及破边等异常结构。检测时大多利用其对光的散射原理,通过显微成像的方式成像在 CCD 中,再结合相关的图像处理软件实现对表面缺陷的识别和分类^[10-13]。

本文通过显微散射法来完成光学元件表面缺陷图像的采集,如图 1(a)所示。为提高表面缺陷的检测效率和精度,需结合图像处理软件完成对表面缺陷的进一步处理。首先通过图像预处理,使用滤波算法消除表面缺陷图像的背景噪声,平滑图像降低不相关信息的干扰,利用形态学处理,能消除表面缺陷的毛刺和填补孔洞,降低了空气中灰尘所造成的干扰,增加了表面缺陷轮廓提取的精确性。阈值分割则有效地将表面缺陷和背景分割出来,便于对表面缺陷特征的提取,最后利用最小外接矩形(minimum enclosing rectangle, MER)对表面缺陷进行描述,如图 1(b)所示。



(a) 原始图像



(b) 图像处理后图像

图 1 表面缺陷图像

Fig. 1 Surface defect images

常见表面缺陷大多分为划痕和麻点 2 类,而在采用 CCD 相机进行图像采集时,空气中的灰尘也会产生散射光,从而成像在 CCD 中,我们将这类散射光形成的信息称为噪点。因此本文针对表面缺陷成像的特性,将分类目标确认为划痕、麻点和噪点 3 类。

目前,卷积神经网络逐渐成为所有识别和检测任务的主导方法^[14-17],不仅具有更好的泛化性能,且具有很强的抗噪声能力,因此本文采用卷积神经网络模型用于光学元件表面缺陷的分类。该模型将工件表面缺陷数据集作为模型的输入,使用卷积层和池化层提取数据的内部特征,将提取的特征输入到 Softmax 分类器进行分类,以提高反射镜表面缺陷分类的准确性。

2 基于卷积神经网络的表面缺陷分类

2.1 表面缺陷数据集

如图 2 所示,得到表面缺陷的 MER,分别计算表面缺陷 MER 的长轴、短轴和外接矩形面积 S_{MER} ,并得到表面缺陷所占的像素即面积 S 。通过(1)式,可以得到表面缺陷的矩形度。

$$P = \frac{S}{S_{MER}} \quad (1)$$

对于光学元件的表面缺陷,经过人工的初步筛选,基本满足了使用标准,表面缺陷在光学元件中存在的数量较少。

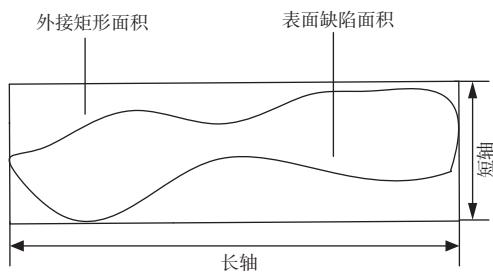


图 2 表面缺陷 MER 模型

Fig. 2 MER model of surface defects

在检测过程得到的图像, 麻点类的表面缺陷多为 μm 级别, 划痕类缺陷长宽比大致为 $1:10\sim1:50$, 对于光学元件, 其表面粗糙度 $R_a \leq 0.5 \text{ nm}$, 表面光洁度较高, 因此图像中的噪点多是由空气中的灰尘所造成的。

通过图 1(b)可以看出, 图中共包括划痕 1 个(蓝色)、麻点 10 个(红色)、噪点 15 个(绿色), 通过 MER 模型得到表面缺陷的长、宽和面积等信息, 其中噪点各数据之间的相似度较高。本文主要分析划痕、麻点和噪点的差异性, 统计了图 1(b)中的部分数据, 其中包括噪点 5 个(序号 12, 11~13)、麻点 5 个(序号 16~20)、划痕 1 个(序号 26), 如表 1 所示。因噪点所占的像素比例少, 其 MER 无法包含整个缺陷区域, 往往存在 $S_{\text{MER}} < S$, 而对于麻点和划痕则有 $S_{\text{MER}} > S$, 其结果在 0~1 变化, 当 $P=1$ 时, 表面缺陷为矩形。

表 1 表面缺陷特征提取

Table 1 Feature extraction of surface defects

| 表面缺陷 | 长轴/ pixel | 短轴/ pixel | 面积/ pixel ² | 外接矩形 面积/pixel ² | 长宽比 | 矩形度 P |
|------|--------------|--------------|---------------------------|-------------------------------|------|---------|
| 1 | 1 | 1 | 4 | 1 | 1 | 4 |
| 2 | 1 | 1 | 4 | 1 | 1 | 4 |
| 11 | 3 | 1 | 8 | 3 | 3 | 2.67 |
| 12 | 2 | 2 | 8 | 4 | 1 | 2 |
| 13 | 3 | 2 | 10 | 6 | 1.5 | 1.67 |
| 16 | 8 | 6 | 48 | 50 | 1.33 | 0.96 |
| 17 | 9 | 8 | 56 | 72 | 1.13 | 0.78 |
| 18 | 11.26 | 7.73 | 69 | 87.07 | 1.46 | 0.79 |
| 19 | 10.29 | 9.84 | 78 | 101.20 | 1.05 | 0.77 |
| 20 | 32.65 | 31.75 | 88 | 104.28 | 1.03 | 0.84 |
| 26 | 87.74 | 28.87 | 1376 | 2532.95 | 3.1 | 0.54 |

光学元件表面缺陷图像大多为暗背景的亮像。针对这类图像, 卷积神经网络是目前主流的做法, 光学元件表面缺陷图像分类流程图如图 3 所

示。在表面缺陷的像素矩阵中, 表面缺陷区域存在连通域, 是可以被观测到的。根据这个矩阵, 光学元件图像将会根据表面缺陷像素的大小进行划分。原始采集的光学元件表面缺陷图像的大小是 768×576 像素。考虑到我们分辨的表面缺陷尺寸大多是人眼极限分辨率以下的, 即长轴 $\leq 100 \mu\text{m}$, 通过相机标定得到实际尺寸和像素之间的比例为 $0.83:1$, 因此我们设计的判别区域的大小是 120×120 个像素。

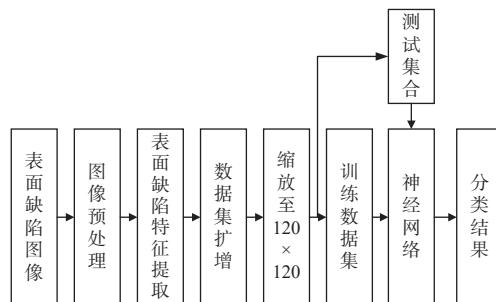


图 3 光学元件表面缺陷图像分类流程图

Fig. 3 Classification flow chart of surface defect images of optical elements

为了平衡不同样本的数量, 本文实验中采集了 900 张表面缺陷图像。其中表面缺陷图像中划痕、麻点和噪点各 300 张。经过随机选择 180 张作为测试集, 其余 720 张作为训练集。

为了防止训练过程中的过拟合, 将图片进行数据扩增, 考虑到表面缺陷的成像特征, 如图 4 所示, 通过对表面缺陷图像进行旋转以及对镜像的方式来扩充图像, 通过对不同方位表面缺陷图像的特征提取, 可以加强网络的训练能力, 提高分类的精确度。

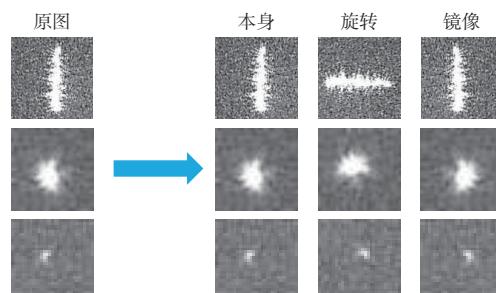


图 4 表面缺陷图像数据集的建立

Fig. 4 Establishment of dataset for surface defect images

2.2 卷积网络模型的建立和优化

光学元件表面缺陷图像的在线检测, 其目的是识别并分类表面缺陷, 并且保证图像在经过旋转、

镜像等后,依然可以识别。因此本文采用 AlexNet 网络^[3], AlexNet 是在 LeNet 的基础上加深了网络的结构,主要分为输入层、特征提取器和分类器,如图 5 所示。

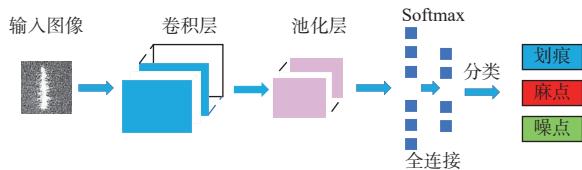


图 5 AlexNet 网络模型

Fig. 5 AlexNet network model

为提升网络的计算性能,本文采用非对称卷积(asymmetric convolution, AC)替换 AlexNet 中的卷积层以训练网络模型^[18]。其原理如(2)式所示。输入特征图 I ,先进行 $K^{(1)}$ 和 I 卷积, $K^{(2)}$ 和 I 卷积后再对结果进行相加,与先进行 $K(1)$ 和 $K(2)$ 的逐点相加后再和 I 进行卷积得到的结果是一致的。

$$I * K^{(1)} + I * K^{(2)} = I * (K^{(1)} \oplus K^{(2)}) \quad (2)$$

如图 6 所示,AC 的整体过程分为训练和推理阶段,因为卷积是大多数网络的基础组件,因此实验都是针对 3×3 卷积进行的。训练阶段就是将现有网络中的每一个 3×3 卷积换成 1×3 卷积+ 3×1 卷积+ 3×3 卷积共 3 个卷积层,最终将这 3 个卷积层的计算结果进行融合获得卷积层的输出。用融合后的卷积核参数初始化现有网络,通过 1×3 和 3×1 卷积对 3×3 方形核的中心十字进行加强,增强了 3×3 卷积核十字区域的图像特征的提取参数,再

利用 3×3 卷积核进行计算,得到卷积层的输出。该网络对于旋转和镜像的图像具有较好的鲁棒性,在推理阶段的计算量不会增加,且提升了 CNN 网络的核心特征提取能力。

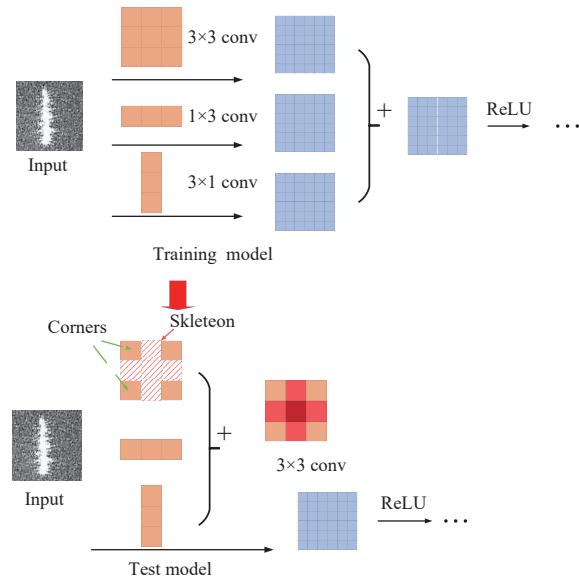


图 6 非对称卷积过程

Fig. 6 Asymmetric convolution process

本文所使用的网络结构将表面图像块输入至神经网络中时,特征提取器主要包括非对称卷积层和池化层,使用 3×3 的卷积核进行卷积操作,然后执行 3×3 的池化操作,接着继续执行卷积和池化,最后计算全连接层与分类器的最终分类。该模型被广泛应用于特征提取环节,本文所用网络的模型如图 7 所示。

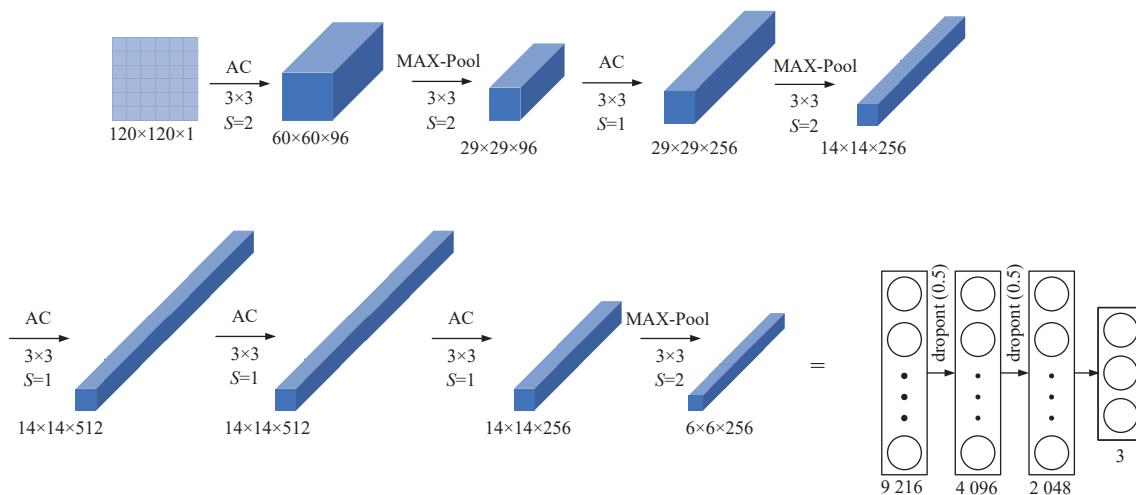


图 7 本文网络结构

Fig. 7 Proposed network structure

本文方法用以分类 120×120 光学元件表面缺陷图像。在特征提取部分, 此处的 AC 均为核大小 3×3 的非对称性卷积, 再通过 ReLU 激活函数输入给下一级网络层。MAX-Pool 为最大池化层, 对特征图像进行降采样处理。对于分类部分采用全连接层结合 dropout 层实现表面缺陷图像的 3 分类。

本文使用 3×3 的非对称卷积代替原本 AlexNet 模型中大小为 11×11 和 5×5 的卷积层, 同时全连接层的输出节点数设置为 2 048。对于整体网络参数来说, 既减小了参数量, 又增加了网络的分线性拟合能力。通过表 2 可以看出, 改进后的网络模型比原本的 AlexNet 模型参数量减小了 6%。

表 2 改进前后网络模型参数量的对比

Table 2 Comparison of network model parameters before and after improvement

| 模型 | 模型总参数 |
|------------|------------|
| Alexnet | 58 271 811 |
| Alexnet+AC | 54 405 027 |

卷积神经网络内卷积层与池化层交替出现, 在卷积层内, 经过卷积核的卷积操作与激活函数的处理等过程, 光学元件表面缺陷图像相关数据会生成光学图像表现缺陷轮廓特征图。在池化层内, 光学元件表面图像相关数据会依照减采样算子实施减采样操作。

在图 7 所示的卷积神经网络结构内, 采用 Softmax 分类器, 利用(3)式可表示分类器的激活函数:

$$k_{\theta}(x^{(i)}) = \frac{1}{\sum_{j=1}^r e^{\theta_j^T x^{(i)}}} \begin{bmatrix} e^{\theta_1^T x^{(i)}} \\ \dots \\ e^{\theta_r^T x^{(i)}} \end{bmatrix} \quad (3)$$

式中: k_{θ} 和 θ 表示输出分类概率向量和分类器输出层与输入层间的参数向量; i 和 r 分别表示第 i 个训练样本和分类数量; x 表示输入层内输入的图像样本; k_{θ} 取值范围为 $[0, 1]$, 总和为 1。

式(4)为训练所用的代价函数:

$$J(\theta) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{j=1}^r i f(u^{(i)} = j) \log \frac{e^{\theta_j^T x^{(i)}}}{\sum_{l=1}^r e^{\theta_l^T x^{(i)}}} \right] \quad (4)$$

式中: m 和 u 分别表示训练样本总量和输出结果。

首先, 光学元件表面缺陷图像作为第一层的输入, 然后, 卷积层与池化层对输入图像执行特征提取和维度降采样, 将特征信息整合在全连接层作

为下一步的输出特征。在全连接层之后使用参数为 0.5 的 dropout 层, 可以避免网络训练时的过拟合现象。经过 dropout 层后的全连接层在训练时, 其节点数会以 0.5 倍缩减因子实现随机缩减, 有效地减少了网络的训练参数, 在提高了网络非线性拟合的同时缩短了训练时间。

输出特征使用 Softmax 分类器执行分类, 经过不断强化训练, 提高其分类性能, 进一步探索这些特征的类别, 提高分类的准确性, 并做出新的决策。

3 实验结果及讨论

将光学元件表明缺陷图像数据按照 4:1 划分为训练集和测试集, 在训练时, 将其随机翻转并归一化到 $[-1, 1]$ 输入至网络中。由于实验设备限制, batch_size 设置为 16, steps_per_epoch 设置为 100, 为了保证得到最好的训练效果, 实验 epoch 设置为 200。训练使用 Adam 优化器, 学习率设置为 1×10^{-4} 。本文在 Linux 环境下进行实验, 深度学习框架采用 Tensorflow2.1 的 GPU 版本, 硬件配置为 2 块 NVIDIA RTX 2060。

本实验将测试集的数据使用卷积网络模型进行分类, 得到的结果如表 3 所示, 划痕与麻点识别的准确率较高, 而噪点识别准确率较低。由于噪点特征的随机性变化较大且其在整幅表面缺陷图像中所占的像素比较小, 缺陷特征复杂程度更高, 因此容易造成结果的误判。本文算法的识别精度都在 97% 以上, 对于常规的光学元件表面缺陷的识别和分类具有一定的稳定性。

表 3 本文网络识别结果

Table 3 Identification results of proposed network %

| 表面缺陷 | Scratch | Dig | Noisy |
|------|---------|-------|-------|
| 准确率 | 100 | 99.75 | 97.4 |

为了验证本文所采用的网络结构在光学元件表面缺陷在线分类的有效性和精确性, 本文实验与其他 4 种经典的神经网络模型相对比, 其结果如表 4 所示。

表 4 模型对比实验

Table 4 Model comparison experiments

| Model | 灵敏度/% | 特异性/% | 精确性/% | 运行时间/s |
|-------------|--------------|--------------|--------------|--------------|
| VGG16 | 69.39 | 91.20 | 96.40 | 81.1 |
| InceptionV3 | 71.74 | 92.29 | 97.12 | 79.35 |
| ResNet50 | 73.87 | 94.17 | 97.32 | 78.56 |
| AlexNet | 77.20 | 92.34 | 97.20 | 18.54 |
| Ours | 89.97 | 96.73 | 99.05 | 18.46 |

实验的评价指标采用包括灵敏度(Sensitivity)、特异性(Specificity)、精确性(Precision)和算法运行时间(Times)共 4 个不同的性能指标对本文的模型进行整体充分评估。各指标计算公式如式(5)、式(6)和式(7)所示。

$$\text{Precision} = \frac{TP}{TP+FP} \quad (5)$$

$$\text{Sensitivity} = \frac{TP}{TP+FN} \quad (6)$$

$$\text{Specificity} = \frac{TN}{TN+FP} \quad (7)$$

式中: TP 真阳性(true positives)表示被正确识别为正例的个数; FP 假阳性(false positive)表示被错误识别为正例的个数; TN 真阴性(true negative)表示被正确识别为负例的个数; FN 假阴性(false negative)表示被错误识别为负例的个数。

使用相同的表面数据集训练其他 4 种经典神经网络 VGG16、ResNet50、InceptionV3 与 AlexNet 进行比较, 本文模型方法在 4 个评价指标中均取得最高值, 灵敏度达到 89.97%。本文模型的分类准确率达到 99.05%, 相比其余 4 个神经网路, 提高了分类的准确性。在时间上本文模型的时间最短, 用时 18.46 s, 通过迁移学习提高了神经网络的性能, 使训练时间降低。综合结果表明, 本文模型的分类性能优于传统神经网络模型。

4 结论

光学元件的表面缺陷会直接影响光学系统的性能。为了有效实现光学元件表面缺陷的分类, 本文提出一种基于卷积神经网络的光学元件表面缺陷分类方法, 将表面缺陷分为划痕、麻点和噪点 3 类。实验中考虑到表面缺陷特征的复杂性, 通过对图像的旋转和镜像处理, 在不改变表面缺陷特征的情况下扩增了数据集, 再采用非对称卷积训练网络模型, 提高了网络的核心提取能力。与原本的 AlexNet 网络相比, 本文方法在降低 6% 参数量的同时, 使分类精度提升 1.85%, 通过与其他深度学习模型性能对比实验, 可以看出本文使用的模型具有较高的分类性能, 这表明该模型在光学元件表面缺陷识别和分类领域中具有较深远的前景。

参考文献:

- [1] RAVIKUMAR S, RAMACHANDRAN K, SUGUMARAN V. Machine learning approach for automated visual inspection of machine component[J]. *Expert Systems with Applications*, 2011, 38(4): 3260-3266.
- [2] MEHRAN P, DEMIRLI K, SURGENOR B. Fuzzy machine vision based clip detection[J]. *Expert Systems*, 2013, 30(4): 352-366.
- [3] KRIZHEVSKY A, SUTSKEVER I, HINTON G. Image net classification with deep convolutional neural networks[J]. *Advances in Neural Information Processing Systems*, 2012, 60(6): 1097-1165.
- [4] LIU Dong, YAGN Yongying, WANG Lin, et al. Microscopic scattering imaging measurement and digital evaluation system of defects for fine optical surface[J]. *Optics Communications*, 2007, 278(2): 240-246.
- [5] 王贵林, 朱俊辉, 李嘉祥, 等. 大口径光学元件表面疵病在位检测与评价研究[J]. *应用光学*, 2019, 40(6): 1167-1173.
- [6] WANG Guilin, ZHU Junhui, LI Jiaxiang, et al. In situ detection and evaluation of surface defects of large aperture optical components[J]. *Journal of Applied Optics*, 2019, 40(6): 1167-1173.
- [7] JIANG Hongzhen, LIU Yong, LIU Xu, et al. Quantitative measurement for the structure of defects on optical surface with lensless Fourier transform digital holographic microscopy[J]. *Optik-International Journal for Light and Electron Optics*, 2016, 127(15): 5865-5869.
- [8] WANG Kungjeng, HAO Fanjiang, LEE Yaxuan, A multiple-stage defect detection model by convolutional neural network[J]. *Computers & Industrial Engineering*, 2022, 168: 108096.
- [9] 范勇, 陈念年, 高玲玲, 等. 大口径精密表面疵病的数字化检测系统[J]. *强激光与粒子束*, 2009, 21(7): 5.
- [10] FAN Yong, CHEN Niannian, GAO Lingling, et al. Digital detection system for large-caliber precision surface defects[J]. *Intense Laser and Particle Beam*, 2009, 21(7): 5.
- [11] RWAGASORE E M, ZHANG X, GAO K, et al. Convolutional neural network for sapphire ingots defect detection and classification[J]. *Optical Materials*, 2021, 119(9): 111292.
- [12] 谢世斌, 杨甬英, 刘东, 等. 精密表面疵病检测美标数字化评价实现算法[J]. *应用光学*, 2015, 36(2): 266-271.
- [13] XIE Shibin, YANG Yongying, LIU Dong, et al. Digital evaluation algorithm for precision surface defects detection[J]. *Journal of Applied Optics*, 2015, 36(2): 266-271.
- [14] 李璐, 杨甬英, 曹频, 等. 大口径光学元件表面灰尘与麻点检测[J]. *应用光学*, 2019, 40(6): 1167-1173.

- 点自动判别[J]. 强激光与粒子束, 2014, 26(1): 109-114.
LI Lu, YANG Yongying, CAO Pin, et al. Automatic identification of dust and pitting on the surface of large aperture optical element[J]. High Power Laser and Particle Beams, 2014, 26(1): 109-114.
- [12] DUAN Y, LIU S, HU C, et al. Automated defect classification in infrared thermography based on a neural network[J]. NDT & E International, 2019, 107: 102147.
- [13] 赵博, 史迎馨. 卷积神经网络的高精密光学元件表面缺陷检测[J]. 激光杂志, 2021, 42(11): 5.
ZHAO Bo, SHI Yingxin. Surface defect detection for high precision optical components based on convolutional neural network[J]. Laser Journal, 2021, 42(11): 5.
- [14] HE Y, HU C, LI H, et al. A flexible image processing technique for measuring bubble parameters based on a neural network[J]. Chemical Engineering Journal, 2022, 429: 132-138.
- [15] Makantzakis K, Karantzalos K, Doulamis A, et al. Deep supervised learning for hyperspectral data classification through convolutional neural networks[C]// Geoscience & Remote Sensing Symposium. USA: IEEE, 2015: 4959-4962.
- [16] BANDHU A, ROY S S. Classifying multi-category images using deep learning: a convolutional neural network model[C]// IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology. Ban-galore: IEEE, 2017: 915-919.
- [17] 马建, 韩卫光. 基于卷积神经网络的工件表面缺陷检测方法[J]. 组合机床与自动化加工技术, 2021(1): 106-109.
MA Jian, HAN Weiguang. Workpiece surface defect detection method based on convolutional neural network[J]. Modular Machine Tool & Automatic Manufacturing Technology, 2021(1): 106-109.
- [18] DING X, GUO Y, DING G, et al. ACNet: strengthening the kernel skeletons for powerful CNN via asymmetric convolution blocks[C]// International Conference on Computer Vision, USA: IEEE, 2019: 1911-1920.

（上接第 667 页）

- [14] 杨佳文, 黄巧林, 韩友民. Zernike 多项式在拟合光学表面形中的应用及仿真[J]. 航天返回与遥感, 2010, 31(5): 49-55.
YANG Jiawen, HUANG Qiaolin, HAN Youmin. Application and simulation in fitting optical surface with Zernike

- polynomial[J]. [Spacecraft Recovery Remote Sensing](#), 2010, 31(5): 49-55.
- [15] 单宝忠, 王淑岩, 牛憨笨, 等. Zernike 多项式拟合方法及应用[J]. 光学精密工程, 2012, 10(3): 318-323.
SHAN Baozhong, WANG Shuyan, NIU Hanben, et al. Zernike polynomial fitting method and its application[J]. [Optics and Precision Engineering](#), 2012, 10(3): 318-323.