

结合轻量化与级联深度神经网络的导光板缺陷检测方法

李俊峰^{1*}, 何炎森¹, 戴文战²

¹浙江理工大学机械与自动控制学院, 浙江 杭州 310018;

²浙江工商大学信息与电子工程学院, 浙江 杭州 310018

摘要 针对车载导航导光板图像纹理背景复杂渐变、亮度不均匀、缺陷细微且类型多等特点,并根据导光板光学特性、网点排列、缺陷成像效果等,结合轻量化与级联深度学习网络提出了一种缺陷快速检测方法。首先,根据导光板缺陷分布特点,通过改进卷积层连接与特征图下采样的方法,设计一轻量化二分类网络实现疑似缺陷区域的快速分割;其次,利用改进的 ResNet 网络构建多分类网络,并提出两阶段网络级联的方法,对分割的疑似缺陷区域提取多样化特征实现缺陷的精确分类;然后,采用固定窗口在完整导光板图像上滑动,将滑动窗口图像裁剪后批量输入级联网络进行缺陷的粗定位与分类;最后,利用工业现场采集的导光板图像自建数据集,并以此为基础进行了大量实验。实验结果表明:与其他导光板缺陷检测算法相比,本文算法在准确率与检测时间上得到显著提升,检测平均准确率达到 98.4%,单张检测时间提升到 1.95 s,准确率、实时性均达到工业检测要求。

关键词 图像处理; 缺陷检测; 导光板缺陷; 轻量化网络; 改进的 ResNet 网络; 级联融合

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP202158.1410009

Light Guide Plate Defect Detection Combining Light Weight and Cascade Deep Learning Network

Li Junfeng^{1*}, He Yansen¹, Dai Wenzhan²

¹ School of Mechanical Engineering and Automation, Zhejiang Sci-Tech University, Hangzhou, Zhejiang 310018, China;

² School of Information and Electronic Engineering, Zhejiang Gongshang University, Hangzhou, Zhejiang 310018, China

Abstract According to the characteristics of complex gradient, uneven brightness, subtle defects, and multiple types of car navigation light guide plate image texture background, and according to the optical characteristics of light guide plate, dot arrangement, defect imaging effect, etc., a fast defect detection method combined with lightweight and cascaded deep learning network is proposed. First, based on the characteristics of defect distribution of the light guide plate, by improving the convolutional layer connection and the down-sampling method of the feature map, a lightweight two-classification network was designed to quickly segment the solid line suspected defect area. Second, the improved ResNet network was used to construct a multi-classification network. The lightweight network and the multi-classification network were cascaded and merged, and diversified features were extracted from the segmented suspected defect regions to achieve accurate defect classification. Then, defect region could be located and recognized by predicting images which were from fixed windows sliding on the completed light guide plate. Finally, a self-built dataset of light guide plate images collected from the industrial field was used, and a large number of experiments are carried out on this basis. Experimental results show that the average accuracy of the detection algorithm for light guide plate defects detection is 98.4%, and the single detection time is 1.95 s. The

收稿日期: 2020-09-28; 修回日期: 2020-11-01; 录用日期: 2020-11-14

基金项目: 国家自然科学基金(61374022)、浙江省公益性技术应用研究计划项目(LGG18F030001, GG19F030034)

通信作者: *ljf2003@zstu.edu.cn

accuracy and real-time performance meet the requirements of industrial detection.

Key words image processing; defect detection; light guide plate defects; lightweight network; improved ResNet network; cascade fusion

OCIS codes 100.4996; 150.1135; 150.1835

1 引言

导光板作为液晶屏背光模组的重要组成成分,其产品质量直接影响液晶屏的显示效果。当前导光板质量检测主要依靠工人在强光下裸眼进行缺陷查验,检测效率低下,而且容易造成漏检,同时人工接触易造成二次伤害。随着计算机、机器视觉、机器学习等技术的发展,自动光学检查(AOI)系统的检测精度与效率不断提高,甚至远超人工检测^[1]。将AOI系统应用到导光板缺陷检测中,可以提高检测效率,降低漏检率,同时无接触检测方式还可以避免导光板的二次伤害。

近年来,国内外学者对液晶屏及相关组件AOI系统的缺陷检测算法开展研究,取得了一系列成果。张沪强等^[2-4]针对导光板表面缺陷检测问题提出设计不同滤波器进行缺陷增强,并根据缺陷区域形态学特征进行缺陷的提取与判定,该方法对图像质量要求较高,在复杂的工业背景下易出现误检、漏检;张亚洲等^[5]采用纹理能量测度方法提取图像纹理特征,并采用高斯混合模型作为导光板表面缺陷检测模型;Jian等^[6]在进行手机屏幕玻璃缺陷检测时提出基于轮廓的配准方法生成模板图像,同时改进模糊c均值聚类方法进行缺陷检测;Ming等^[7]提出基于动态权重组合分类器的导光板缺陷检测方法,通过对多种不同分类器进行动态权重分配找出分类效果最好的组合方式,以取得远超单一分类器的分类效果;Cen等^[8]针对薄膜晶体管液晶显示器(TFT-LCD)面板的表面缺陷检测提出了一种基于低秩矩阵重构的缺陷检测算法,通过重建低秩矩阵分离出破坏低秩矩阵结构的缺陷区域。这些基于传统机器视觉、机器学习的缺陷检测方法需要手动提取特征,过程复杂,并缺乏鲁棒性和通用性,不适合工程应用。

随着深度学习技术的发展,不少基于深度学习的缺陷检测方法被广泛应用在各种工业场景中,包括太阳能、液晶面板、铁路交通、金属材料等各个领域^[9-12]。Deitsch等^[13]采用修改的VGG19网络识别分辨率为 300×300 的太阳能电池面板图像缺陷,识别效果超过手工特征设计方法,但采用直连结构使得参数量与计算量较大,算法效率较低;Yuan等^[14]基于改进的分割方法,进行手机保护玻璃表面

缺陷的提取与测量,该方法在网络中添加了阈值处理步骤,针对手机玻璃图像背景单一、亮度均匀的情况可以取得较好的缺陷区域分割效果,但对背景复杂、亮度变化明显的缺陷图像检测效果较差;Chen等^[15]级联了两个目标检测网络与一个分类网络进行铁路沿线紧固件连接缺陷处的定位与分类,该网络结构可以实现小目标的定位与检测,但多个复杂网络进行级联使得检测时间增加,无法实现实时检测;Xie等^[16]在两级分层深度卷积神经网络的基础上,提出了一套用于下水道缺陷分类的全自动系统,可以很好地识别视频中不同类别的下水道缺陷,但该两级分层结构中共用了同一特征提取网络,无法深层挖掘相似正负样本间显著性差异,在检测精度要求较高的工业领域准确率无法达到要求;Nagata等^[17]提出基于卷积神经网络与支持向量机相融合的高精度异常检测方法,用以检查在树脂模塑制品中出现的不良缺陷,该方法将传统机器学习方法与深度学习方法相结合,取得了较好的检测效果,但使用卷积神经网络进行特征向量的提取与转化过程较为复杂,不利于工程实践;柳锋等^[18]结合深度学习语义分割与机器视觉方法进行导光板表面各类缺陷检测,该方法在规则背景下可以较好地分割出各类缺陷,但无法适应导光板复杂变化的背景,极易产生误检。

基于上述缺陷检测方法存在的特征提取复杂、算法实时性不足、检测准确率较低等问题,本文以车载导航液晶屏的导光板为研究对象,根据其在高分辨率工业相机下的成像特点及工业检测要求,提出一种结合轻量化与级联深度学习网络的导光板缺陷快速检测方法。首先其通过设计的轻量化二分类网络实现疑似缺陷区域快速分割;其次,利用改进的ResNet残差网络构建另一四分类网络,并将其与轻量化网络进行级联融合,实现对疑似缺陷区域的精确分类;最后,在采用特定数据增强方法基础上构建导光板数据集,并将网络集成到自主研发的检测系统,通过对完整导光板图像进行预处理和滑动窗口^[19]实现导光板缺陷定位与分类。实验结果表明,该检测方法无需复杂的手动特征提取过程,其检测速度和缺陷分类精度与其他方法相比得到显著提高,实时性与准确率均满足工业检测需求。

2 车载导航导光板缺陷分类

车载导航导光板的质量检测精度要求比较高,需要检出 $10\ \mu\text{m}$ 以上的缺陷,工业面阵相机难以满足要求。本文检测系统采用 16k 线阵相机呈现车载




图 1 导光板局部图像

Fig. 1 Partial images of light guide plate

本文主要研究导光板缺陷中点缺陷、线缺陷、面缺陷的快速检测与分类。

根据生产厂家技术要求、一线工人工作经验以及导光板成像特点,采集大量导光板缺陷图像进行分析,可将车载导航导光板的表面缺陷分为以下几类:点缺陷、线缺陷、面缺陷。这些缺陷在图像上占据几个到几十个像素,其形成的原因及特征如下。

1) 点缺陷

导光板注塑成型过程中,塑胶熔料中存在固体杂质、空气中粉尘浓度过大或者模具过于粗糙均会造成其表面产生点缺陷。点缺陷成像特征表现为某一导光点亮度明显大于周围导光点,面积也比正常导光点略大,成像图像如图 2(a)所示。

2) 线缺陷

导光板在成型与传输的过程中,其表面与传输介质进行密切接触时会产生较大摩擦导致导光板表面产生线缺陷。其成像特点表现为长度超过一定范围的线性轮廓,宽度在几个像素点内,轻微线缺陷宽度在一个像素点内,肉眼难以分辨。线缺陷在工业相机下成像图像如图 2(b)所示。




图 2 导光板各类缺陷图像。(a)点缺陷;(b)线缺陷;
(c)面缺陷

Fig. 2 Various defects on light guide plate. (a) Dot defect; (b) line defect; (c) area defect

导航导光板的清晰图像,采集的高分辨率图像大小为 10084×14500 ,其局部图像如图 1 所示,可以看出,导光板图像具有很多导光网点,纹理背景复杂;而且,由于车载导航导光板采用单侧入光式结构,导光点从左到右越来越密集,图像也逐渐模糊。

3) 面缺陷

导光板表面与其他较大异物接触过程中产生的大摩擦力,或在远距离传输过程中接触到机油、异物等,均会在导光板表面形成面缺陷。面缺陷成像图像表现为无规则、面积偏大的亮暗区域或区域轮廓,其图像如图 2(c)所示。

3 结合轻量化与级联深度学习网络的导光板缺陷检测方法

分析导光板缺陷图像可以发现,导光板缺陷成像极其细微,在图像上仅占据几个像素点,同时各类缺陷如点、线、面缺陷的灰度、圆度、纹理等形态学特征变化明显,传统的缺陷检测方法难以准确地提取各类缺陷的特征进行度量,导致检测精度较低。基于此,本文提出了一种结合轻量化与级联深度学习网络的导光板缺陷快速检测方法,其检测流程如图 3 所示。

首先,采用特定数据增强方法分别制作导光板图像正常与缺陷二类以及正常与多缺陷四类数据集;其次,设计轻量化网络对正常和缺陷样本进行二分类,以便快速定位疑似缺陷区域,并使用二类数据集对网络进行训练;然后使用四类数据集训练改进的 ResNet 网络,并将该网络级联到轻量化网络,从而对轻量化网络分出的疑似缺陷类图像提取各自特有特征,通过网络的分类器确认是否为缺陷并进行准确分类;最后,在原始高分辨率导光板图像上进行预处理和滑动窗口截取图像,将截取图像批量输入网络,通过恢复的网络参数对图像进行精确的缺陷检测与分类。

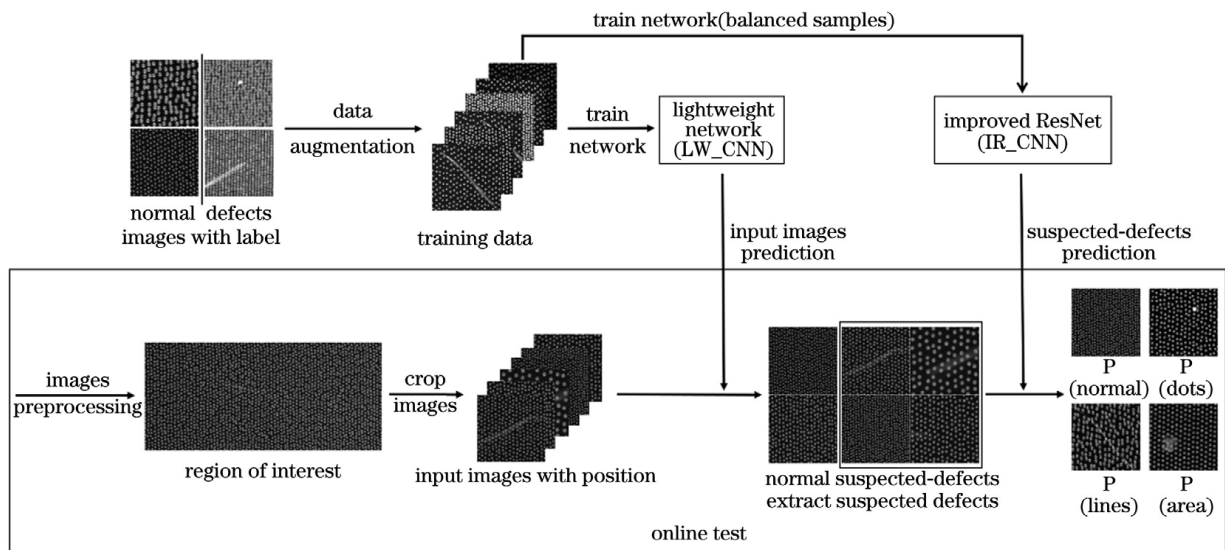


图 3 导光板缺陷检测方法结构图

Fig. 3 Structure of defect detection of light guide plate

3.1 数据集制作

导光板生产线对导光板质量具有严格的把控标准,因此导光板缺陷产生量较少,同时缺陷产生具有随机性。制作完整的缺陷数据集共有以下步骤:缺陷产品收集与分类、图像采集与样本截取、图像数据增强、数据集划分。

缺陷产品收集与分类主要由生产线检验人员完成,在进行导光板的缺陷检验时,将不符合质量标准的导光板挑出并按照点、线、面缺陷分类放置。然后使用线扫相机采集各类缺陷导光板图像,以缺陷位置为中心采用固定分辨率为 224×224 的矩形框进行随机角度、随机偏移量的样本截取,并将截取的样本按各自类别分别保存。

对截取的缺陷样本进行数据增强,本文所采用

的数据增强方法主要是亮度调节、缺陷背景替换与融合、旋转变换方法。其中亮度随机调节公式为

$$f(x, y) = f'(x, y) \cdot \delta, 0.85 \leq \delta \leq 1.15, (1)$$

式中: $f'(x, y)$ 为原始图像像素灰度值; $f(x, y)$ 为调节后图像像素灰度值; δ 为亮度调节系数,其值为 $0.85 \sim 1.15$ 的随机数。

缺陷背景替换与融合方法是从原始缺陷样本图像中分割出缺陷区域并生成模板图像,然后选择无缺陷导光板样本图像作为背景图像,将模板图像与背景图像尺寸调整到一致后相加融合,具体过程如图 4 所示。通过缺陷背景替换与融合的方法,可以增加类内样本量,同时平衡类间样本量,提高算法的鲁棒性。最后将样本图像进行 90° 、 180° 旋转,增加样本数量,提高算法的旋转不变性。




图 4 缺陷背景替换与融合

Fig. 4 Replacement and fusion of defect background

将所有样本图像按照表 1 方式划分数据集 1、2。其中,从数据集 1 正类样本中进行随机筛选得到数据集 2 正常样本类;将数据集 1 中负类样本进行

点、线、面缺陷分类得到数据集 2 中点、线、面缺陷类样本。考虑到导光板图像本身存在类别不平衡问题,将数据集 1 中正负类样本比例设置为近似

表 1 数据集设置
Table 1 Dataset setting

| Dataset | Kind | Number | Training | Validation | Test |
|----------|---------------------|--------|----------|------------|------|
| Dataset1 | Positive(normal) | 15500 | 10850 | 1550 | 3100 |
| | Negative(defective) | 11373 | 7962 | 1138 | 2273 |
| Dataset2 | Normal | 4000 | 2800 | 400 | 800 |
| | Area | 3706 | 2595 | 371 | 740 |
| | Lines | 3967 | 2777 | 397 | 793 |
| | Dots | 4197 | 2938 | 420 | 839 |

1.5 : 1; 数据集 2 中各类样本比例设置为近似 1 : 1 : 1 : 1。数据集 1、2 均按照 70%、10%、20% 的比例划分训练集、验证集与测试集。

3.2 轻量化网络设计

传统卷积神经网络如 AlexNet^[20]、VGG^[21]、GoogLeNet^[22]、ResNet^[23] 等虽取得较好的分类及检测效果,但并未在网络结构上做效率方面的优化,因

此使用这些网络进行导光板缺陷检测无法达到时间要求。近年来,Google 团队提出了 MobileNet^[24-25] 系列网络,通过改进网络结构与连接方式,节约大量的计算量,提高网络的预测速度。本文以 MobileNet 系列网络设计思想为基础,通过改进卷积层连接方式与特征图下采样方式,构建适用于导光板图像的轻量化卷积神经网络(LW_CNN),网络的具体结构如图 5 所示。

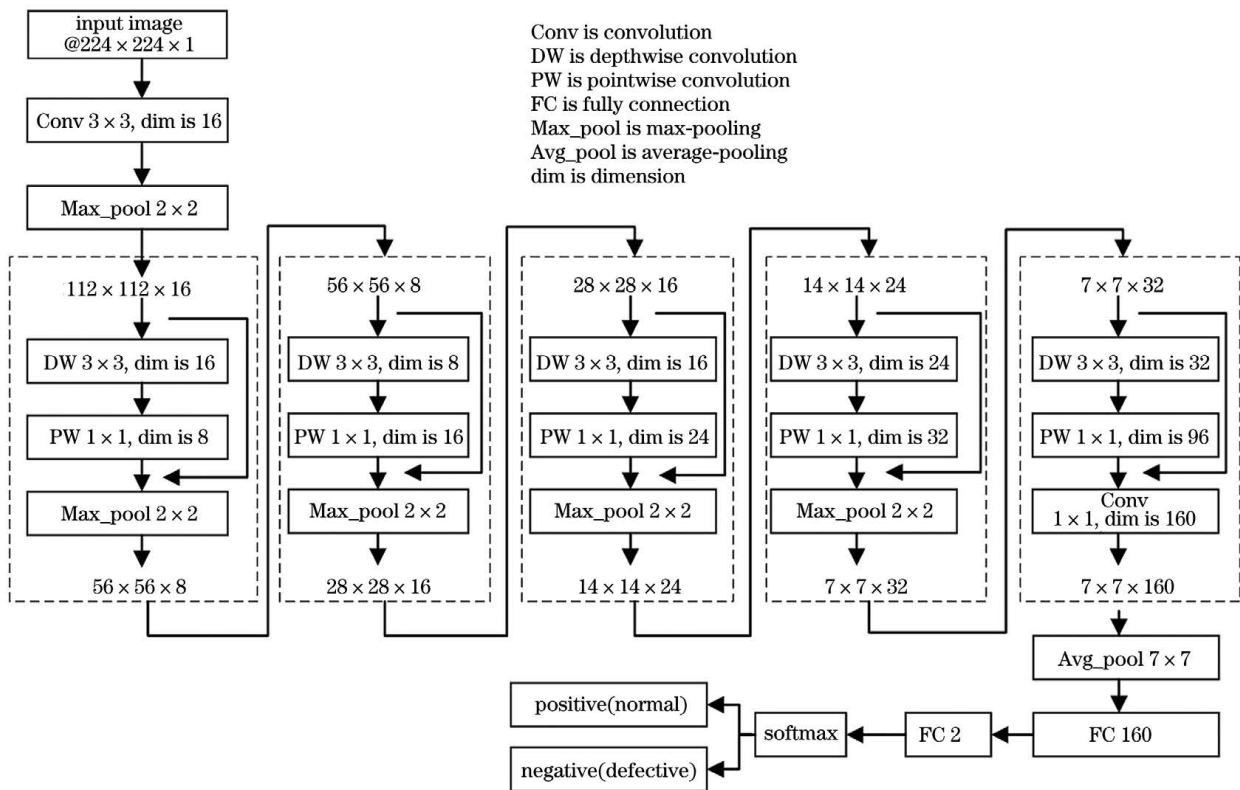


图 5 轻量化网络结构

Fig. 5 Structure of LW_CNN

本文设计的轻量化网络共有 2 层标准卷积层(Conv)、5 个轻量化模块、6 层池化层、2 层全连接层(FC)以及 1 层 softmax 层。在所有卷积运算层后均进行批归一化操作以防止训练时发生过拟合,使用 ReLU 非线性函数激活,网络各层结构与作用

如下。

1) 标准卷积层

网络的输入端及网络末端分别设置卷积核大小为 7×7 与 1×1 的标准卷积层,其中 3×3 标准卷积层主要作用是对输入的单通道图像进行浅层特征提

取与特征图维度提升;1×1 标准卷积层主要作用是提升特征图维度,并将提取的特征转化为向量输入全连接层中进行分类。标准卷积层定义的卷积方式将特征图维度从 M 维提升到 N 维,即

$$[W, H, M] \otimes [F, F, M, N] \Rightarrow [W', H', N], \quad (2)$$

式中: W 、 H 、 M 分别为输入特征图的宽、高、维度; W' 、 H' 、 N 分别为输出特征图的宽、高、维度; F 为卷积核大小; \otimes 为卷积运算。

特征图输出宽、高计算公式为

$$W' = \left\lfloor \frac{W - F + 2P}{S} + 1 \right\rfloor, \quad (3)$$

$$H' = \left\lfloor \frac{H - F + 2P}{S} + 1 \right\rfloor, \quad (4)$$

式中: P 为池化大小; S 为水平与垂直方向步长。

2) 轻量化模块

本文利用深度可分离卷积设计了如图 6 所示的轻量化模块。该模块使用步长与池化参数固定的 3×3 深度级卷积(DW)和 1×1 逐点卷积(PW)操作进行输入特征图的特征提取与维度提升。其主要作用是通过输入与输出间的跨层连接减少特征信息的丢失,同时降低网络的计算量,提高网络的预测速度。




图 6 轻量化模块

Fig. 6 Lightweight module

当输入特征图为 $F: D_F \times D_F \times M$, 输出特征图为 $G: D_F \times D_F \times N$, 使用步长为 1 的标准卷积 $K: D_K \times D_K \times M \times N$ 进行操作时,其计算量 P_{Conv} 为

$$P_{Conv} = D_F * D_F * D_K * D_K * M * N. \quad (5)$$

相同输入输出情况下,使用深度级卷积为 DW: $D_K \times D_K$, 逐点卷积为 PW: $1 \times 1 \times M \times N$, 步长为 1 的轻量化模块进行卷积操作时,其计算量 P_{Light} 为

$$P_{Light} = D_F * D_F * D_K * D_K * M + D_F * D_F * M * N. \quad (6)$$

相同输入输出特征图情况下使用轻量化模块进行卷积操作与使用标准卷积操作的计算量对比为

$$\frac{P_{Light}}{P_{Conv}} = \frac{1}{N} + \frac{1}{D_K^2}. \quad (7)$$

从(7)式中可以看出,当卷积核尺寸为 3,即 $D_K=3$ 时,轻量化模块与标准卷积模块相比计算量为 $1/9 \sim 1/8$,理论上可以显著降低网络计算量,提高网络预测速度。

3) 池化层

轻量化网络共有 6 个池化层,其中 5 个最大池化层(Max_pool)和 1 个平均池化层(Avg_pool)。5 个最大池化层分别位于网络前端标准卷积模块与轻量化模块之后,平均池化层位于网络末端 1×1 标准卷积层之后。最大池化层的主要作用是对特征图进行下采样,降低特征图尺寸,同时在一定邻域内进行最大化操作有利于增强网络的平移不变特性,提高模型的鲁棒性。平均池化层的主要作用是对特征信息进行压缩,增强网络的不变性,同时取代全连接层进行特征的向量化,降低参数与计算量。

4) 全连接层与 softmax 层

网络末端采用全连接层对网络提取到的图像特征进行分类,将分类结果经 softmax 层归一化后输出,网络输出缺陷类与正常类各自归一化概率,并选取其中概率最大的一类作为结果输出。

3.3 改进的 ResNet 模型

轻量化网络的设计目的是提升算法的检测速度,但单一的轻量化网络在多类缺陷划分问题上存在精度不足问题。针对此问题,本文在轻量化网络上级联一个改进的 ResNet 网络(IR_CNN),该网络主要对轻量化网络提取出的疑似缺陷区域实现点、线、面缺陷的精确分类,同时为进一步降低正常类的影响,在该网络末端添加正常样本类,即改进的 ResNet 网络实现四分类。网络的具体结构如图 7 所示。

改进后的网络包含 3 层 1×1 卷积层、16 层 3×3 卷积层、2 层全连接层、1 层 softmax 层。每层卷积层后进行批归一化操作以防止网络训练过程中产生过拟合,所有层均采用 ReLU 非线性函数进行激活。主要改进方法为将 7×7 卷积层与最大池化层替换为 3 个 5×5 的卷积层,以提取导光板缺陷图像更多的形态学和尺寸信息,同时防止最大池化的过程中损失细节信息。同时,修改全连接层的层数与神经元数量,提高对导光板图像细节信息分类的准确率。网络中共有 8 次残差连接,即将输入特征图与输出特征图进行跨层连接。当特征图尺寸与维度不发生变化时,将输入特征图与输出特征图直




图 7 改进的 ResNet 网络结构

Fig. 7 Structure of IR_CNN

接进行残差连接;当特征图尺寸与维度发生变化的时候,先对输入特征图进行 1×1 卷积操作调整尺寸与维度,然后将其与输出特征图进行残差连接。残差连接可以防止网络训练过程中发生梯度消失与梯度爆炸的问题,提升网络的深度,同时便于图像的特征信息在网络的浅层与深层之间进行传递,有利于提取导光板缺陷图像更多的抽象特征信息,实现更为精确的分类。网络最后使用 softmax 层将全连接层输出转化为概率输出,并选择最大概率对应类别作为网络输出。

3.4 损失函数

轻量化网络与改进的 ResNet 网络输出端均使用 softmax 层实现概率的归一化,采用交叉熵损失函数计算输出概率与标签之间的距离,即

$$\hat{y}_i = \text{softmax}(x_i) = \frac{\exp(x_i)}{\sum_{j=1}^n \exp(x_j)}, \quad (8)$$

式中: \hat{y}_i 为原始输出 $x_1, \dots, x_i (1 \leq i \leq n)$ 经 softmax 层归一化后的输出概率; $\sum_{j=1}^n \exp(x_j)$ 为原始输出的指数和。

输出与图像标签之间的交叉熵损失 $E(y_i, \hat{y}_i)$ 为

$$E(y_i, \hat{y}_i) = - \sum_i y_i \ln(\hat{y}_i), \quad (9)$$

式中: $y_1, \dots, y_i (1 \leq i \leq n)$ 为图像标签值; $\hat{y}_1, \dots, \hat{y}_i$

($1 \leq i \leq n$) 为图像对应的输出。

同时为防止模型训练中发生过拟合,添加 L2 正则项作为惩罚项 $R(w)$,即

$$R(w) = \sum_w w^2, \quad (10)$$

式中: $\sum_w w^2$ 为模型所有参数 w 的平方和。

最终计算网络的损失 $J(w)$ 为

$$J(w) = E(y_i, \hat{y}_i) + \alpha R(w) = - \sum_i y_i \ln(\hat{y}_i) + \alpha \sum_w w^2, \quad (11)$$

式中: α 为正则项系数,本文将正则化系数 α 设置为 0.005。

4 实验结果与分析

4.1 实验装置

本文的车载导航导光板 AOI 实验装置如图 8 所示,主要由工业相机、工控机、机器人等构成。其中,相机进行图像采集,工控机进行图像处理与分析,机器人进行正常产品与缺陷产品的分离。实验采用的软硬件平台配置如下:CPU 为 intel i7-8700K, GPU 为 RTX2060;操作系统为 Windows10,深度学习框架为 pytorch,编程语言为 python3.6,图像处理库为 opencv3.4;深度学习加速工具配置为 CUDA10.0、cuDNN7.6。网络的训练、测试过程均在此配置环境下完成。




图 8 实验装置图。(a)装置三维图;(b)装置实体图

Fig. 8 Experimental device. (a) Three-dimensional device; (b) physical device

4.2 网络训练与可视化分析

本文网络训练过程中采用迁移学习^[26]技术,预先在大型开放数据集 ImageNet 上进行网络的训练,提取预训练网络模型特征提取层参数作为网络初始化参数,然后在导光板表面缺陷数据集上进行模型再训练。为简化参数设置过程,将网络优化算法与超参数进行固定。其中,轻量化网络与改进的 ResNet 网络均采用自适应优化算法 Adam 进行训练,初始化学率均设置为 0.001,训练总轮数设置为 60,批量训练大小设置为 32,一阶矩估计参数、二阶矩估计参数默认设为 0.9、0.999, Epsilon 参数防止在实施过程中除以 0。

参数设置完成后进行训练,训练过程中损失变化曲线如图 9 所示。从曲线中可以看出,网络在训练过程中虽然产生轻微振荡,但总体损失呈下降趋势。其中,轻量化网络在迭代到 5000 次左右逐渐收敛,改进的 ResNet 网络在迭代到 2000 次左右基本收敛。

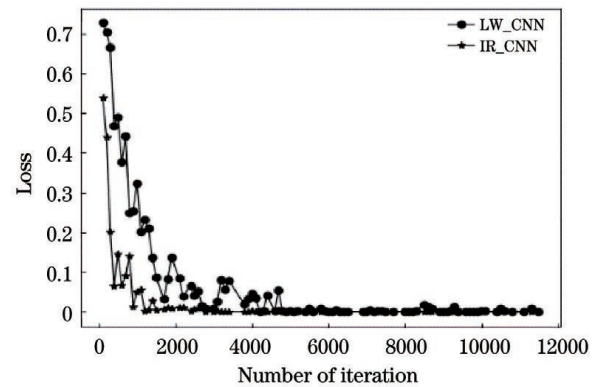


图 9 训练曲线

Fig. 9 Training curve

网络训练完成后,将轻量化网络与改进的 ResNet 网络末端卷积层输出的部分特征图重映射后进行可视化,可视化结果如图 10 所示。从图中可以看出,轻量化网络可以大致提取出缺陷样本特征,能够有效区分正常与缺陷样本类。而经过改进后的 ResNet 网络可以有效提取点、线、面缺陷特征并与




图 10 部分特征图可视化。(a)正常;(b)点缺陷;(c)线缺陷;(d)面缺陷

Fig. 10 Visualization of partial feature map. (a) Normal; (b) dot defect; (c) line defect; (d) area defect

正常区域形成了鲜明对比,可视化结果初步证明算法的设计思路行之有效。

4.3 实验对比分析

本文实验对比分析主要分为两大部分:首先是在自建数据集上对算法各级网络进行性能测试,并与其他网络进行对比,分析算法设计的合理性;其次是将算法集成到设计的检测系统上,在采集的完整导光板缺陷图像上进行缺陷检出准确率与检测速度的测试,并与其他导光板缺陷检测算法进行对比,分析本文算法对导光板缺陷检测准确率与速度的影响。

在完成轻量化网络的设计与 ResNet 网络的改

进后,使用轻量化网络与改进的 ResNet 网络在数据集 1、数据集 2 上实现二分类与四分类任务。并使用经典的分类网络 VGG19、MobileNetV2、ResNet18 实现导光板缺陷数据集分类。不同分类网络在导光板数据集上测试的二分类准确率、四分类准确率、计算量(FLOPs)、每秒预测样本数如表 2 所示。从测试结果可以看出,本文设计的轻量化网络在二分类准确率变化不大的情况下,计算量显著降低,每秒预测样本数远高于其他网络。改进的 ResNet 网络与其他网络相比,其分类准确率最高。将轻量化网络与改进的 ResNet 网络进行级联融合可以有效提高算法的预测速度与分类准确率。

表 2 不同分类网络在导光板数据集上的测试结果

Table 2 Test results of different classification networks on light guide plate dataset

| Network | 2-classes | | 4-classes | | | FLOPs /G | Speed /s ⁻¹ | |
|-----------------------------|-----------|------------|--------------|--------------|--------------|--------------|------------------------|------------|
| | Normal /% | Defects /% | Normal /% | Area /% | Lines /% | | | Dots /% |
| VGG19 ^[21] | 97.54 | 97.21 | 97.25 | 97.03 | 97.22 | 97.74 | 19.61 | 232 |
| ResNet18 ^[23] | 99.58 | 99.52 | 99.50 | 98.92 | 98.87 | 98.33 | 1.74 | 427 |
| MobileNetv2 ^[25] | 98.86 | 99.33 | 99.46 | 97.33 | 96.68 | 98.49 | 0.06 | 660 |
| LW_CNN | 99.65 | 99.63 | 98.52 | 93.32 | 98.25 | 95.79 | 0.02 | 811 |
| IR_CNN | 99.77 | 99.78 | 99.63 | 99.32 | 98.99 | 99.17 | 7.63 | 320 |

将网络按前文所示检测方法结构图进行级联融合后,将模型部署到检测系统中。通过工业现场多条生产线上的实验装置共采集 500 张完整导光板图像,经检验人员确认并手动分类。其中,正常无缺陷

导光板图像 150 张,存在各类缺陷导光板图像 350 张。利用本文算法与文献[18]方法分别对导光板图像进行检测,检测结果如表 3 所示。

表 3 本文算法与文献[18]方法对比

Table 3 Comparison of algorithm in this paper and method in Ref. [18]

| Defect type | Number | Accuracy of proposed method /% | Accuracy of method in Ref. [18] /% | Speed of proposed method /s ⁻¹ | Speed of method in Ref. [18] /s ⁻¹ |
|-------------|--------|--------------------------------|------------------------------------|---|---|
| Normal | 150 | 100.00 | 96.00 | | |
| Area defect | 85 | 98.82 | 87.06 | | |
| Line defect | 127 | 96.85 | 96.85 | 1.95 | 6.8 |
| Dot defect | 138 | 97.83 | 95.65 | | |
| Average | 500 | 98.40 | 94.60 | | |

在文献[18]方法中,首先进行大量样本像素级的标注,然后搭建语义分割网络并进行训练,最后将分割出来的结果进行形态学特征判断,其优点在于可以控制所筛选缺陷尺寸。但在使用其方法进行车载导航光板缺陷检测时,由于面缺陷形态、尺寸变化差异大,检测效果较差。与文献[18]方法相比,本文算法针对各类缺陷的检出率更高,单张导光板检

测时间显著降低。实验证明,本文算法提高了导光板缺陷的检出率,显著提高了缺陷检测速度。

5 结 论

针对导光板缺陷检测过程中速度过慢与检测精度不足的问题,本文提出了基于轻量化与级联深度学习网络的导光板缺陷快速检测方法。通过设计轻

量化网络实现疑似缺陷区域的快速分割,同时将改进的 ResNet 网络级联到轻量化网络实现对分割出的疑似缺陷区域的准确分类。实验结果表明,该算法设计合理,算法实际运行时的检测时间、精度均达到工业检测要求,能够实现车载导航导光板表面缺陷快速精准的检测,具有较高的工业应用价值。

参 考 文 献

- [1] Liao H C, Lim Z Y, Hu Y X, et al. Guidelines of automated optical inspection (AOI) system development[C]//2018 IEEE 3rd International Conference on Signal and Image Processing (ICSIP), July 13-15, 2018, Shenzhen, China. New York: IEEE Press, 2018: 362-366.
- [2] Zhang H Q, Li J F, Dai W Z. Single side entrance light guide plate quality visual inspection method[J]. Computer Systems & Applications, 2020, 29(2): 219-227.
张沪强, 李俊峰, 戴文战. 单边侧入光式导光板质量可视化检测方法[J]. 计算机系统应用, 2020, 29(2): 219-227.
- [3] Li J F, Li M R. Research on detecting method of light guide plate defect based on machine vision[J]. Journal of Optoelectronics·Laser, 2019, 30(3): 256-265.
李俊峰, 李明睿. 基于机器视觉的导光板缺陷检测方法研究[J]. 光电子·激光, 2019, 30(3): 256-265.
- [4] Li J F, Li M R. Research on slight line scratch detection method of light guide plate based on multi-directional Gabor filter[J]. Journal of Optoelectronics·Laser, 2019, 30(4): 395-401.
李俊峰, 李明睿. 基于多方向 Gabor 滤波的导光板轻微线刮伤检测方法研究[J]. 光电子·激光, 2019, 30(4): 395-401.
- [5] Zhang Y Z, Lu X L. Surface defect detection method of light-guide plate based on improved coherence enhancing diffusion and texture energy measure-Gaussian mixture model [J]. Journal of Computer Applications, 2020, 40(5): 1545-1552.
张亚洲, 卢先领. 基于改进相干增强扩散与纹理能量测度和高斯混合模型的导光板表面缺陷检测方法[J]. 计算机应用, 2020, 40(5): 1545-1552.
- [6] Jian C X, Gao J, Ao Y H. Automatic surface defect detection for mobile phone screen glass based on machine vision[J]. Applied Soft Computing, 2017, 52: 348-358.
- [7] Ming W Y, Shen F, Zhang H M, et al. Defect detection of LGP based on combined classifier with dynamic weights[J]. Measurement, 2019, 143: 211-225.
- [8] Cen Y G, Zhao R Z, Cen L H, et al. Defect inspection for TFT-LCD images based on the low-rank matrix reconstruction [J]. Neurocomputing, 2015, 149: 1206-1215.
- [9] Zhang G S, Ge G Y, Zhu R H, et al. Gear defect detection based on the improved YOLOv3 network [J]. Laser & Optoelectronics Progress, 2020, 57(12): 121009.
张广世, 葛广英, 朱荣华, 等. 基于改进 YOLOv3 网络的齿轮缺陷检测[J]. 激光与光电子学进展, 2020, 57(12): 121009.
- [10] Zhou J, Jing J F, Zhang H H, et al. Real-time fabric defect detection algorithm based on S-YOLOV3 model[J]. Laser & Optoelectronics Progress, 2020, 57(16): 161001.
周君, 景军锋, 张缓缓, 等. 基于 S-YOLOV3 模型的织物实时缺陷检测算法[J]. 激光与光电子学进展, 2020, 57(16): 161001.
- [11] Shen X H, Li Z H, Li M, et al. Aluminum surface-defect detection based on multi-task deep learning[J]. Laser & Optoelectronics Progress, 2020, 57(10): 101501.
沈晓海, 栗泽昊, 李敏, 等. 基于多任务深度学习的铝材表面缺陷检测[J]. 激光与光电子学进展, 2020, 57(10): 101501.
- [12] Tao X, Hou W, Xu D. A survey of surface defect detection methods based on deep learning [J]. Acta Automatica Sinica, 2021, 47(5): 1017-1034.
陶显, 侯伟, 徐德. 基于深度学习的表面缺陷检测方法综述 [J]. 自动化学报, 2021, 47(5): 1017-1034.
- [13] Deitsch S, Christlein V, Berger S, et al. Automatic classification of defective photovoltaic module cells in electroluminescence images[J]. Solar Energy, 2019, 185: 455-468.
- [14] Yuan Z C, Zhang Z T, Su H, et al. Vision-based defect detection for mobile phone cover glass using deep neural networks [J]. International Journal of Precision Engineering and Manufacturing, 2018, 19(6): 801-810.
- [15] Chen J W, Liu Z G, Wang H R, et al. Automatic defect detection of fasteners on the catenary support device using deep convolutional neural network [J]. IEEE Transactions on Instrumentation and Measurement, 2018, 67(2): 257-269.
- [16] Xie Q, Li D W, Xu J X, et al. Automatic detection and classification of sewer defects via hierarchical deep learning[J]. IEEE Transactions on Automation Science and Engineering, 2019, 16(4): 1836-1847.
- [17] Nagata F, Tokuno K, Nakashima K, et al. Fusion method of convolutional neural network and support vector machine for high accuracy anomaly detection

- [C] // 2019 IEEE International Conference on Mechatronics and Automation (ICMA), August 4-7, 2019, Tianjin, China. New York: IEEE Press, 2019: 970-975.
- [18] Liu F, Li J F, Dai W Z. Defect detection method of light guide plate based on deep learning semantic segmentation[J]. Computer Systems & Applications, 2020, 29(6): 29-38.
柳锋, 李俊峰, 戴文战. 基于深度学习语义分割的导光板缺陷检测方法[J]. 计算机系统应用, 2020, 29(6): 29-38.
- [19] Cha Y J, Choi W, Büyüköztürk O. Deep learning-based crack damage detection using convolutional neural networks [J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32(5): 361-378.
- [20] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [21] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [EB/OL]. (2015-04-10) [2020-09-28]. <https://arxiv.org/abs/1409.1556>.
- [22] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 1-9.
- [23] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [24] Howard A G, Zhu M, Chen B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications [EB/OL]. (2017-04-17) [2020-09-28]. <https://arxiv.org/abs/1704.04861v1>.
- [25] Sandler M, Howard A, Zhu M L, et al. MobileNetV2: inverted residuals and linear bottlenecks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 4510-4520.
- [26] Pan S J, Yang Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.