

一种平板玻璃表面缺陷检测方法

郑天雄^{a,b}, 冯胜^{a,b}, 伍凯凯^{a,b}, 游泓清^{a,b}, 谢博娅^{a,b}

(湖北工业大学 a.机械工程学院 b.精密光电测量技术与仪器研究所, 武汉 430068)

摘要: **目的** 针对平板玻璃缺陷检测中灰尘干扰划痕、亮点检测的问题, 提出一种基于全反射-掠入射组合照明的平板玻璃表面缺陷检测方法。**方法** 通过控制全反射光源和掠入射光源的发光时序, 在相应发光时序内采集玻璃图像, 根据缺陷在不同照明下的灰度纹理差异计算灰度、几何特征等一系列相对偏差特征, 开发 BP 神经网络算法, 实现玻璃表面灰尘和表面缺陷的检测。**结果** BP 神经网络在测试集上各类别预测的查准率、查全率均在 90% 以上, 整体准确率达到 97.2%。**结论** 全反射-掠入射组合照明成像系统结构简单, 降低了玻璃图像中灰尘和内部点缺陷分类难度, 有效减少灰尘和内部缺陷的误判。

关键词: 全反射-掠入射组合照明; 缺陷检测; 自适应阈值分割; 神经网络

中图分类号: TB487; TP391.4 **文献标识码:** A **文章编号:** 1001-3563(2022)13-0257-07

DOI: 10.19554/j.cnki.1001-3563.2022.13.033

Method for Detecting Surface Defects of Flat Glass

ZHENG Tian-xiong^{a, b}, FENG Sheng^{a, b}, WU Kai-kai^{a, b}, YOU Song-qing^{a, b}, XIE Bo-ya^{a, b}

(a. School of Mechanical Engineering b. Institute of Precision Photoelectric Measurement Technology and Instruments, Hubei University of Technology, Wuhan 430068, China)

ABSTRACT: The work aims to propose a surface defect detection method of flat glass based on total reflection-grazing incidence combined lighting to solve the dust interferes with the detection of scratches and bright spots in defect detection of flat glass. By controlling the time sequences of lighting of total reflection and grazing incidence light sources, the glass images of glass in the corresponding time sequences of lighting were collected. The gray-scale, geometric characteristics and a series of relative deviation characteristics were calculated according to the difference of gray-scale texture of defects under different lighting. The BP neural network was developed to detect the dust and defects on the glass surface. In the end, the accuracy and recall rates of each category prediction of the BP neural network on the test set were all above 90%, and the overall accuracy rate reached 97.2%. From this point of view, the total reflection-grazing combined lighting imaging system has a simple structure, which reduces the difficulty of classification of dust and internal point defects in the glass image, and effectively reduces the misjudgment of dust and internal defects.

KEY WORDS: total reflection-grazing incidence combined lighting; defect detection; adaptive threshold segmentation; neural network

随着智能手机、平板电脑等电子设备的广泛使用, 触摸面板的需求量不断扩大, 推动了平板玻璃表面缺陷无损检测方法和设备的研究发展。在对玻璃平

板原材料进行拉伸、切割、磨边、钢化等深加工过程中, 机械或者人为会导致气泡、划痕、崩边等缺陷的产生。生产线上的缺陷检测仍以人工目视为主, 但人

收稿日期: 2021-11-13

基金项目: 国家自然科学基金 (12074110)

作者简介: 郑天雄 (1997—), 男, 湖北工业大学硕士生, 主攻机器视觉和模式识别。

通信作者: 冯胜 (1971—), 男, 博士, 湖北工业大学教授, 主要研究方向为精密光学测量。

工检测效率低、稳定性差、成本高。基于机器视觉的缺陷检测具有快速、准确、低成本、无损耗等特点,十分契合玻璃的表面缺陷检测的现有需求,因此相关方法和设备的研究成为该领域近年来的热点。

检测过程中灰尘属于可修复的缺陷,而点缺陷、划痕属于不可修复的缺陷,即当玻璃上仅有灰尘缺陷时,产品仍可以经过处理后正常出品。由于灰尘在常规照明下与玻璃的点状缺陷极为相似,检测时容易产生误判。将灰尘误识别为点状缺陷会导致合格品被报废,造成资源浪费,而将点状缺陷误识别为灰尘会导致不合格品被漏检,降低出品质量,因此现有视觉检测方法主要通过2种思路解决灰尘对检测的影响:保持玻璃清洁,提高检测环境的洁净度,以减少灰尘对检测结果产生干扰;通过光学成像和算法设计提高灰尘和其他缺陷的分类准确率。文中主要讨论后者,即从光学成像和图像处理的角度分析。

龙亮亮等^[1-3]使用图像滤波算法滤除灰尘区域,没有充分考虑灰尘和点状缺陷的相似性,会存在部分点状缺陷被误滤除以及部分灰尘未被滤除的可能性。刘怀广等^[4-5]提出了一种基于纹理的浮法玻璃伪缺陷剔除方法,针对大的灰尘(0.5 mm以上)有较好的伪缺陷剔除效果,但对于尺寸较小的灰尘缺陷区分效果并不理想。Ding等^[6-8]设计了低分辨率成像场配合高精度电控平移台用于缺陷粗定位,再使用高分辨率成像场二次采集用于分类的缺陷图像,并通过处理高分辨率缺陷图像完成对划痕、坑点、灰尘的有效分类。高分辨率成像的方法分类准确可靠,但是系统结构较为复杂,速度较慢,不适用于平板玻璃这类大批量检测任务。Jiang等^[9]建立了一套基于同轴平行成像与明场成像结合的成像系统用于成像。张丹丹等^[10-11]使用背光成像,并使用深度学习完成缺陷识别任务。深度学习对灰尘和其他缺陷有较好的分类结果,但是针对不同类型的玻璃,训练集需要重新制作和训练,任务十分繁重,并不灵活。姚红兵等^[12-13]设计了全内反射暗场来增强缺陷信号强度并降低表面灰尘干扰,但部分尺寸较大或者距离表面较近的灰尘仍无法完全排除其干扰。

在前人研究的基础上,为了解决检测过程中灰尘

干扰的问题,文中旨在研究一种结构简单灵活的玻璃面板缺陷检测方法,使用全反射-掠入射组合光源照明成像,采用局部自适应二值化方法完成缺陷分割,依据灰尘与坑点、划痕在2种成像场下的特征差异计算相对偏差作为缺陷特征,结合全反射暗场下的缺陷几何特征,采用BP神经网络^[14]进行分类训练,完成灰尘、划痕和坑点缺陷的分类与标记。

1 照明与图像采集系统

1.1 照明原理及光源设计

照明的目的是突出被检测物体,提高对比度,常见照明方法仅突显异常区域,但是针对灰尘和气泡的成像没有明显的区分作用,文中系统基于玻璃是透明的,同时具有透射和反射的性质,结合灰尘、划痕、亮点等缺陷本身的散射性质设计了2种成像场,见图1,相机主轴垂直于待检测玻璃表面。图1a中的光源为全内反射光源,安装在待测玻璃两侧,位置度在玻璃上下表面之间。入射光以大于临界角的入射角照射到玻璃表面,玻璃表面或亚表面的缺陷会破坏全内反射的条件,此时划痕、亮点等缺陷散射光会进入相机。图1b中的光源为低角度掠入射光源,安装在待测玻璃两侧,略高于玻璃表面,此时相机主要捕捉灰尘和表面缺陷的散射光。为了表述方便,将图1a中的成像场称为主成像场,图1b中的成像场称为辅成像场。

依据图1中成像原理,自主设计了LED组合光源,为了避免全内反射光源和掠入射光源互相影响,同时限制光源的出射方向和角度:全内反射光源尽可能从侧边进入玻璃内部而不照射上下表面;掠入射光源尽可能照射上下表面而不从侧边进入玻璃。为此在光源出射后加入隔板使不同类型光源进入各自通道,并且满足位置限制条件,光源结构示意图见图2。全内反射所在的通道内壁布置了漫射薄膜,目的是吸收掉非水平方向的光,避免全内反射光源照亮玻璃上下表面,同时为了保证光照的相对均匀,在另一侧也设计对称的光源,图中未画出。

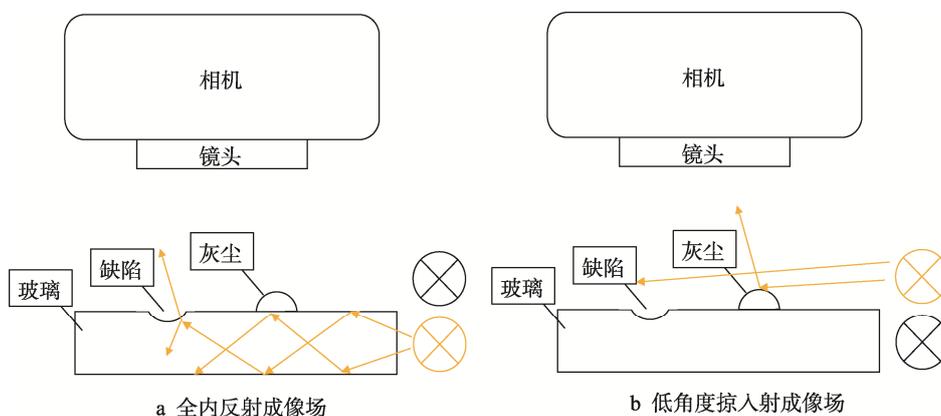


图1 2种成像场
Fig.1 Two imaging fields

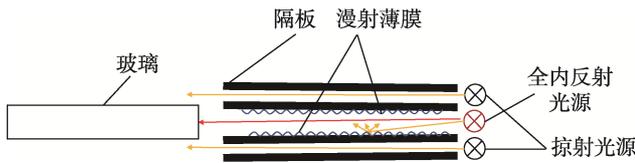


图 2 光源结构
Fig.2 Structure of light source

1.2 图像采集系统及成像

采集系统中传输辊轴由雷赛 DM542 步进式电机驱动, 成像系统包括全反射成像场和低角度掠入射成像场, 其中光源为自主设计的 LED 多列线阵列, 每列可单独控制; 待测玻璃尺寸为 70 mm×150 mm, 设定检测视场宽度为 76 mm, 系统检测精度为 20 μm, 所需的相机横向分辨率至少为 3 800, 因此选用美国 FLIR 公司的单色 CMOS 相机 GS3-U3-89S6M-C, 分辨率为 4 096×2 160。玻璃放置在传输辊轴上传输, 为了获取整张玻璃图像, 相机需要在每个成像场下各进行 6 次采集。每次分别主、辅成像场下采集同一位置图片。对于无缺陷的玻璃样品, 相机将记录一个全暗的背景图像, 而各类型内外部缺陷在主、辅成像场中的图像见图 3。划痕、气泡在主成像场中较亮, 与背景对比度较高; 灰尘在辅成像场中较亮, 与背景对比度较高。

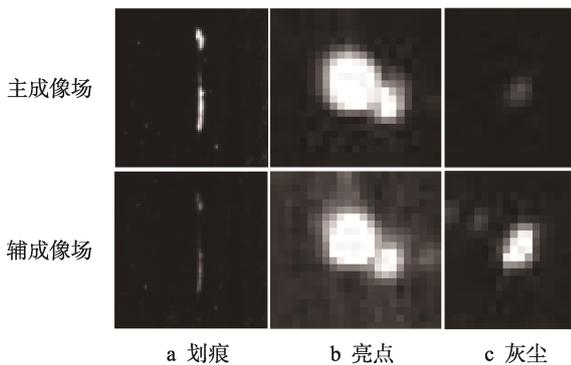


图 3 主、辅成像场中的缺陷图像
Fig.3 Defect images in the main and auxiliary imaging fields

2 分割与分类算法

为了确定图像中缺陷位置和类别, 缺陷检测处理流程见图 4。

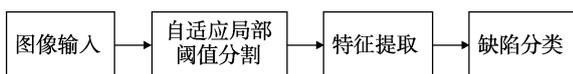


图 4 缺陷检测处理流程
Fig.4 Defect detection processing flow

2.1 自适应阈值分割

缺陷分割是指将图像中的目标缺陷区域与背景分离, 以便进行缺陷区域的特征分析, 是图像处理算

法中重要的一步。常用的缺陷分割方法有基于边缘、阈值和区域的分割方法, 由于基于阈值的方法更为直观, 实现简单且计算速度快, 因此阈值处理是最常用的图像分割技术。

玻璃缺陷这类前景目标占比较小的图片, 灰度直方图往往成单峰分布, 且玻璃缺陷的形态各异, 受其尺寸和角度影响, 部分缺陷, 尤其是深度较浅的划痕缺陷在图像上的灰度值与背景极为接近, 全局阈值法往往效果不佳。自适应局部高斯窗阈值分割方法考虑了目标像素 $m \times m$ 的邻域像素, 使用归一化高斯核求和作为目标像素的阈值依据。

文中使用的二维高斯核 G 的表达式为:

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{(x^2+y^2)}{2\sigma^2}} \quad (1)$$

上述二维高斯核 G 的模板中心为目标像素, (x, y) 表示相对目标像素的邻域坐标, σ 为分布标准差。进一步的, 归一化二维高斯核 g 的表达式为:

$$g(x, y) = \frac{G(x, y)}{\sum_{i=-(m-1)/2}^{(m-1)/2} \sum_{j=-(m-1)/2}^{(m-1)/2} G(i, j)} \quad (2)$$

那么 (x, y) 处像素的局部阈值计算为:

$$T_{xy} = s \cdot \sum_{i=-(m-1)/2}^{(m-1)/2} \sum_{j=-(m-1)/2}^{(m-1)/2} g(x+i, y+j) f(x+i, y+j) \quad (3)$$

式中: s 为局部阈值调整因子; m 为窗口大小, 且为大于 1 的奇数; f 为图像的灰度值。

通过阈值判断 (x, y) 处的像素是否为缺陷异点, 见式 (4)。

$$B(x, y) = \begin{cases} 1 & f(x, y) > T_{xy} \\ 0 & f(x, y) \leq T_{xy} \end{cases} \quad (4)$$

经过实验, 文中选择标准差为 16, 窗口大小为 31×31 的二维高斯核。为了验证使用高斯窗口的局部阈值方法的分割效果, 选取 Otsu 法^[15]、Phansalkar 法^[16]作为全局和局部阈值方法的代表进行比较。各类典型缺陷在主成像场中图像的分割结果见图 5。Otsu 法由于使用全局阈值, 并不适用于图像中不明显的玻璃缺陷的分割, 如低亮度的划痕和亮点就无法提取出来。Phansalkar 法在划痕的低灰度部分, 可能将原本连续的区域分割成多段, 且只能检测出核心较亮部分。相比之下文中使用的局部自适应高斯法针对不同类型的缺陷都有较好的分割效果, 能够分割目标可能包含的外围真实区域, 比如灰尘核心周围区域。

在 4 096×2 160 的测试图像中, 几种算法的耗时见表 1, 其中局部阈值的局部窗口大小为 31×31, 局部高斯阈值方法的耗时略大于 Otsu 方法, 但比同为局部阈值方法的 Phansalkar 有明显优势, 因为 Phansalkar 一类的局部方法需要计算局部窗口的标准差, 计算量较大。综合看来, 文中的二值化方法同时兼顾分割准确性和效率, 能将玻璃图像中的缺陷区域有效分割出来。

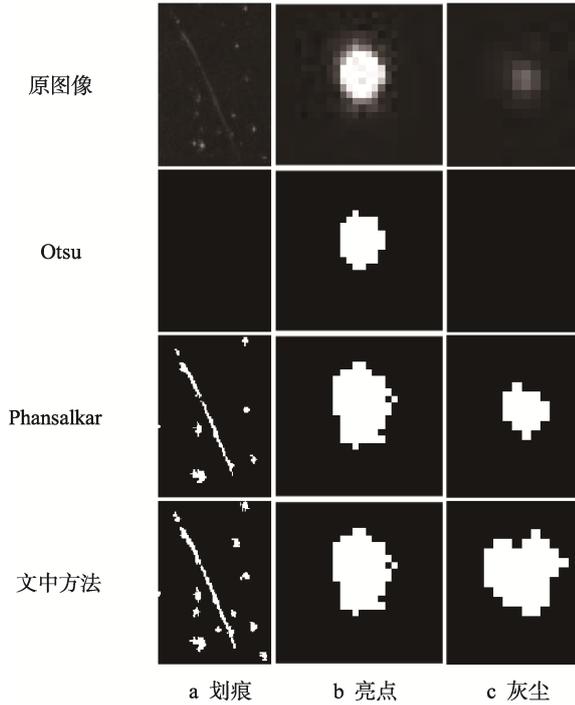


图5 各种分割算法结果对比
Fig.5 Comparison of results of various segmentation algorithms

表1 各种二值化方法的耗时

Tab.1 Time-consuming of various binarization methods

二值化方法	耗时/s
Otsu	0.18
Phansalkar	1.07
文中方法	0.47

2.2 特征提取及分析

经分割后,将计算出的每个缺陷区域的特征参数作为分类器所需的输入值。由于辅成像场中会显出较多的灰尘,增加缺陷特征的计算压力,文中采用主成像场中的图像进行二值化,这样在保证划痕和坑点不会漏检的同时,提高整张图像缺陷特征的计算速度。针对主光源下的灰尘采用文中方法分割的结果见图6,图6a为主成像场中的缺陷图像,图6b为图6a采用文中二值化方法后的二值化结果,图6c为图6a在辅成像场中对应的图像,对应轮廓均由实线标识,缺陷的主成像场图像和辅成像场图像在轮廓范围内存在明显灰度差异。

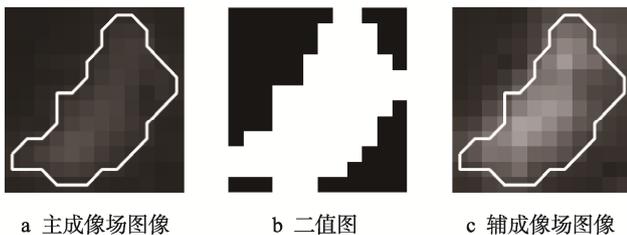


图6 灰尘在主辅成像场成像及二值化
Fig.6 Dust imaging and binarization in the main and auxiliary imaging fields

1) 缺陷区域内平均灰度反映了区域的明暗,平均灰度计算式见式(5)。

$$f_1 = \frac{\sum_{i=1}^k f(i)}{k} \quad (5)$$

式中: k 为一个缺陷区域内像素总数,即缺陷有效面积; $f(i)$ 为区域内第 i 个图像的灰度值,下同。

2) 灰度标准差反映了灰度的集中程度,灰度标准差计算式见式(6)。

$$f_2 = \sqrt{\sum_{i=1}^k (f(i) - f_1)^2} \quad (6)$$

3) 大灰度百分比同样反映了灰度的集中程度,大灰度百分比计算式见式(7)。

$$\begin{cases} h(i) = \begin{cases} 1 & f(i) > f_1 \\ 0 & \text{else} \end{cases} & i = 1, 2, 3, \dots, k \\ f_3 = \frac{1}{k} \sum_{i=1}^k h(i) \end{cases} \quad (7)$$

式中: $h(i)$ 为第 i 个像素灰度大于平均灰度的真假值。

4) 填充度为物体区域面积与区域外接矩形面积之比,反映了缺陷的整体是否倾斜和饱满,计算式见式(8)。

$$f_4 = \frac{k}{S_r} \quad (8)$$

式中: S_r 为区域外接矩形面积。

5) 细长度反映了区域是否为长条扁平区域,细长度计算见式(9)。

$$f_5 = \frac{\max(w, h)}{\min(w, h)} \quad (9)$$

式中: w 、 h 分别为最小外接矩形的宽高。

6) 紧致度反映了缺陷的边界复杂度,计算式见式(10)。

$$f_6 = \frac{C^2}{k} \quad (10)$$

式中: C 为区域边界周长。

7) 矩形度反映区域与矩形的相似程度,计算式见式(11)。

$$f_7 = \frac{k}{S_{MAR}} \quad (11)$$

式中: S_{MAR} 为区域最小外接矩形面积。

另外,为了充分利用2种成像场下缺陷的灰度差异信息,把计算出的灰度特征的一系列相对偏差作为特征值,见式(12)。

$$\begin{cases} d_{f_1} = \frac{f_{1m} - f_{1s}}{f_{1m} + f_{1s}} \\ d_{f_2} = \frac{f_{2m} - f_{2s}}{f_{2m} + f_{2s}} \\ d_{f_3} = \frac{f_{3m} - f_{3s}}{f_{3m} + f_{3s}} \end{cases} \quad (12)$$

式中: f_{1m} 、 f_{1s} 、 f_{2m} 、 f_{2s} 、 f_{3m} 、 f_{3s} 分别为主、辅成像场中区域的平均灰度、灰度标准差和大灰度百分比; d_{f_1} 、 d_{f_2} 、 d_{f_3} 分别为对应特征的相对偏差。

3 种类型缺陷在填充度-细长度-灰度相对偏差三维特征空间中的分布见图 7, 观察到缺陷在空间中明显分为 3 簇。由于划痕细长且有轻微倾斜或弯曲, 细长度大于其他缺陷, 而填充度低于其他缺陷; 灰尘、点缺陷更接近圆形, 所以填充度较高而细长度较低; 灰尘的灰度相对偏差较低, 而点缺陷的灰度相对偏差较高。

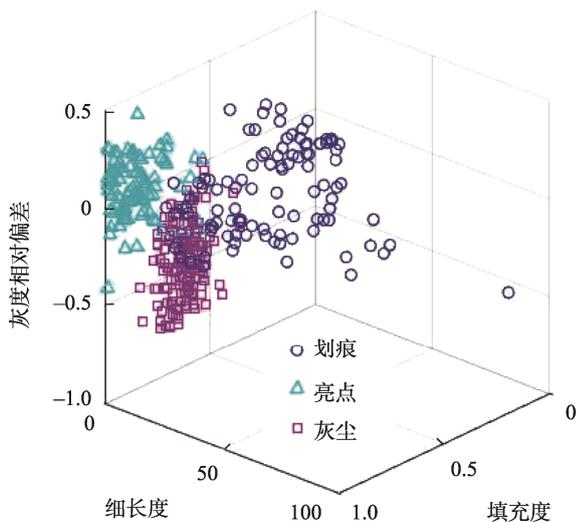


图 7 缺陷在三维特征空间的分布
Fig.7 Distribution of defects in the three-dimensional feature space

2.3 基于 BP 神经网络的缺陷分类

考虑到玻璃缺陷的复杂性, 同一类缺陷可能在某一特征上的分布较分散, 比如缺陷的灰度可能暗也可能亮, 因此不能选择固定的阈值作为分类标准。BP 神经网络作为常用的有监督分类器, 对离群样本有更强的联想推断能力, 训练过程中自适应的调整各神经元间的连接权值, 以寻求最佳的输入输出间的映射函数, 使得损失函数达到最小, 完成分类、回归等任务。文中选择一个典型的 3 层 BP 神经网络作为分类器, 由于描述缺陷的特征有 11 个, 即输入层节点数为 11, 隐含层的节点数可以通过经验公式 (13) 确定大致范围。

$$h = \sqrt{I + O} + \alpha \quad (13)$$

式中: I 为输入特征数量; O 为输出类别数量; h 为隐含层节点数; α 为 1~10 的调节常数。文中输出层节点数为 3, 最终设置隐含层节点数为 10。

BP 网络需要根据损失函数对各层权重的偏导来更新权重进行训练, 多分类问题常设置 softmax 传递

函数输出类别概率, 并用交叉熵损失 (Cross Entropy) 作为损失函数, 见式 (14)。

$$L = \frac{1}{N} \sum_{i=1}^N L_i = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^O y_{ij} \ln(p_{ij}) = -\frac{1}{N} \sum_{i=1}^N \ln(p_{ic}) \quad (14)$$

式中: N 为样本数; O 为类别数; L_i 为第 i 个样本的损失项; p_i 为概率分布, $p_i = [p_{i1}, \dots, p_{iO}]$, 每个元素 p_{ij} 表示样本 i 属于第 j 类的概率; y_i 为样本 i 真实类别的 onehot 编码, $y_i = [y_{i1}, \dots, y_{iO}]$, 当样本 i 真实类别为第 j 类时, $y_{ij} = 1$, 否则 $y_{ij} = 0$; 假设 c 为样本 i 的真实类别标签, p_{ic} 即表示样本 i 的类别被正确预测的概率。

由于实际中玻璃缺陷存在类间不均衡, 这也反映在数据采集的分布中, 数据集中划痕、亮点、灰尘的数量分别为 102、86、162 个, 灰尘数量多于玻璃内部缺陷。为了保证网络训练对各类缺陷都有较好的泛化能力, 采用分层 5 折交叉验证来保证网络训练过程中每折数据具有与源数据相同的类别比例, 其中 4 折用于训练与验证, 且训练与验证比例为 7:3, 剩余 1 折数据用于测试。

3 实验

3.1 评价指标

对于多分类模型问题常用的评价指标有: 宏平均 F1 (Macro-average F1, Macor F1)、微平均 F1 (Micro-average F1, Micro F1)、受试者工作特征曲线 (Receiver Operating Characteristic, ROC) 和各类别的平均精度 (mean Average Precision, mAP) 等。其中 ROC 曲线和 Macro F1 不受样本不平衡的影响, 符合文中样本数据特点, Macro F1 是将多分类的评价指标拆成多个二分类的评价指标, 计算见式 (15)。文中使用 ROC 曲线和 Macro F1 值进行综合评价。

$$\begin{cases} F_i = 2 \frac{R_i \times P_i}{R_i + P_i} \\ F_{\text{macro}_i} = \frac{1}{n} \sum_{i=1}^n F_i \end{cases} \quad (15)$$

式中: R_i 、 P_i 、 F_i 分别为第 i 类的查全率、查准率和调和平均数; n 为类别数。

3.2 训练结果及分析

选取 5 折交叉验证中的验证集中损失函数最低的网络模型, 模型训练曲线见图 8a, 交叉熵损失目标为 10^{-6} , 最大迭代次数为 5 000 次, 第 49 个 epoch 时, 在验证集上损失函数达到最小。3 类缺陷测试集的 ROC 曲线见图 8b, 划痕的 ROC 曲线表现较好, 亮点和灰尘的 ROC 曲线表现稍差, 但整体上分类器的表现很好。

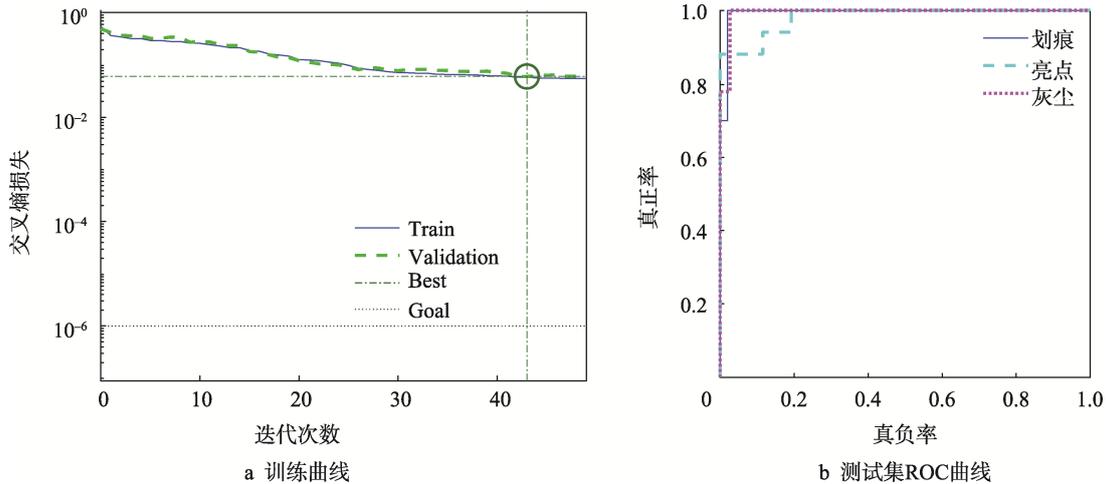


图8 模型训练结果
Fig.8 Model training results

对测试集进行测试,得到混淆矩阵见表2,灰尘和其他2类缺陷仍存在少量互相误判,主要是因为二者在灰度和形态上的特征上十分接近,在边界值处难以区分。3类缺陷预测的查准率、查全率和整体准确率见表3,其中灰尘被误判为划痕会导致样品被判为不合格品,导致资源浪费,发生概率为3%;亮点被误判为灰尘会导致出品为不合格品,影响出品质量,发生概率为5.9%。最终依据式(14)计算各类别F1以及Macor F1,划痕、亮点和灰尘的F1值分别为97.7、97、97,Macro F1综合指标可以达到97.2%。

表2 测试集的混淆矩阵
Tab.2 Confusion matrix for test set

类别	实际数量		
	划痕	亮点	灰尘
文中方法预测	21	0	1
数量	0	16	0
	0	1	32

表3 各类别的查准率、查全率和整体准确率
Tab.3 Accuracy rate and recall rate, namely, overall accuracy rate of each category

类别	查准率/%	查全率/%	整体准确率/%
划痕	95.5	100	
亮点	100	94.1	97.2
灰尘	97	97	

文中算法对现场玻璃检测的局部结果见图9,不同类型缺陷由不同形状标识:划痕由轮廓线标识,亮点由圆圈标识,灰尘由矩形标识,面积过小的异常点不予考虑,共检测到52个有效缺陷,其中划痕1个,亮点1个,灰尘50个,灰尘占比较高,与现场的实际检测条件相符。选取现场经人工检测的200片玻璃,其中有缺陷,即有划痕、亮点的玻璃65片,无缺陷,即仅有灰尘附着的玻璃135片,经系统检测的结果统计见表4。由表4可知,漏检率为6.2%,误检率为16.3%,检测准确率为87%,误检率较高,说明

存在较多处于判定边界状态的灰尘会被误判为亮点类缺陷,但系统针对存在灰尘干扰的玻璃缺陷检测,仍具有一定的可靠性。

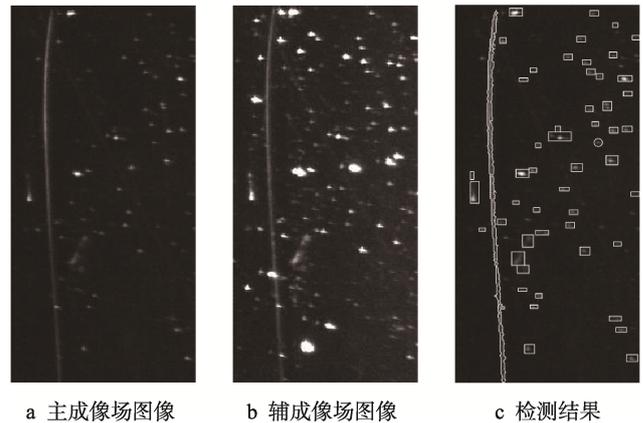


图9 缺陷检测结果
Fig.9 Defect detection results

表4 检测结果统计
Tab.4 Statistics of test results

样本类型	检测数量	准确数量	错误数量	准确率/%
有缺陷	65	61	4	93.8
无缺陷 (仅灰尘)	135	113	22	83.7
总数	200	174	26	87

4 结语

为了解决灰尘干扰现场检测结果,影响出品质量等问题,文中针对缺陷和灰尘的光学特性创新设计了全内反射成像场和低角度掠入射成像场进行成像,对图像使用局部阈值分割算法完成缺陷分割后,提取缺陷在2个成像场中的几何、灰度信息和二者间的差异信息作为特征,使用BP神经网络实现了对玻璃缺陷的分类。系

统在结构简单的同时能够有效区分灰尘和其他 2 类缺陷,为玻璃缺陷检测中灰尘干扰的问题提供了新的解决思路。该系统对主成像场中光源的收敛有较高要求,同时由于灰尘存在,将会有大量的区域进行特征计算,耗时较长,部分特殊灰尘和亮点会被误分类,另外系统针对崩边类缺陷不敏感,因此需要进一步完善系统结构和相应的检测算法,以满足玻璃表面缺陷检测的要求。

参考文献:

- [1] 龙亮亮,刘冠峰,张国英,等. 基于机器视觉的玻璃马赛克缺陷在线检测系统[J]. 机械设计与制造, 2017(S1): 129-132.
LONG Liang-liang, LIU Guan-feng, ZHANG Guo-ying, et al. On-Line Glass Mosaic Defect Detection Based on Machine Vision[J]. Machinery Design & Manufacture, 2017(S1): 129-132.
- [2] 张璐. 基于机器视觉的玻璃缺陷在线检测方法研究[D]. 西安:西安理工大学, 2020: 17-21.
ZHANG Lu. Research on On-Line Detection Method of Glass Defects Based on Machine Vision[D]. Xi'an: Xi'an University of Technology, 2020: 17-21.
- [3] 萧显. 基于机器视觉的手机屏幕玻璃缺陷检测方法研究[D]. 广州: 广东工业大学, 2019: 18-24.
XIAO Xian. Research on Detection Method of Cellphone Screen Glass Defect Based on Machine Vision[D]. Guangzhou: Guangdong University of Technology, 2019: 18-24.
- [4] 刘怀广,陈幼平,谢经明,等. 浮法玻璃缺陷在线识别技术的研究[J]. 小型微型计算机系统, 2011, 32(4): 738-742.
LIU Huai-guang, CHEN You-ping, XIE Jing-ming, et al. Research on Online Recognition Technology for Float Glass Defects[J]. Journal of Chinese Computer Systems, 2011, 32(4): 738-742.
- [5] 彭向前,陈幼平,余文勇. 一种基于机器视觉的浮法玻璃质量在线检测系统[J]. 制造业自动化, 2007, 29(12): 50-52.
PENG Xiang-qian, CHEN You-ping, YU Wen-yong. On-Line Inspection System of Float Glass Quality Based on Machine Vision[J]. Manufacturing Automation, 2007, 29(12): 50-52.
- [6] DING Wen-dong, ZHANG Zheng-tao, ZHANG Da-peng, et al. An Effective On-Line Surface Particles Inspection Instrument for Large Aperture Optical Element[J]. International Journal of Automation and Computing, 2017, 14(4): 420-431.
- [7] LI L, LIU D, CAO P, et al. Automated Discrimination between Digs and Dust Particles on Optical Surfaces with Dark-Field Scattering Microscopy[J]. Applied Optics, 2014, 53(23): 5131-5140.
- [8] 楚红雨,谢志江,邵延华,等. 基于机器视觉的光学元件表面洁净度检测仪研制[J]. 现代科学仪器, 2010(3): 17-20.
CHU Hong-yu, XIE Zhi-jiang, SHAO Yan-hua, et al. Development of Surface-Cleanliness Inspection Instrument for Optical Element Based on Machine Vision[J]. Modern Scientific Instruments, 2010(3): 17-20.
- [9] JIANG Jia-bin, CAO Pin, LU Zi-chen, et al. Surface Defect Detection for Mobile Phone back Glass Based on Symmetric Convolutional Neural Network Deep Learning[J]. Applied Sciences, 2020, 10(10): 3621-3634.
- [10] 张丹丹. 基于改进卷积神经网络的玻璃缺陷识别方法研究[D]. 太原: 中北大学, 2019: 45-46.
ZHANG Dan-dan. Research on Glass Defect Recognition Method Based on Improved Convolutional Neural Network[D]. Taiyuan: North University of China, 2019: 45-46.
- [11] 瓮佳良. 基于深度学习的玻璃缺陷识别方法研究[D]. 太原: 中北大学, 2017: 46-47.
WENG Jia-liang. The Research on Glass Defect Recognition Method Based on Deep Learning[D]. Taiyuan: North University of China, 2017: 46-47.
- [12] 姚红兵,马桂殿,沈宝国,等. 基于机器视觉的树脂镜片疵病检测系统研究[J]. 激光与光电子学进展, 2013, 50(11): 112-119.
YAO Hong-bing, MA Gui-dian, SHEN Bao-guo, et al. Flaws Detection System for Resin Lenses Based on Machine Vision[J]. Laser & Optoelectronics Progress, 2013, 50(11): 112-119.
- [13] 倪开灶,刘世杰. 基于改进的全内反射显微技术检测玻璃亚表面缺陷[C]// 第十六届全国光学测试学术交流会议摘要集, 上海, 2016: 28.
NI Kai-zao, LIU Shi-jie. Detecting Defects of Glass Sub-surface by Improved Total Internal Reflection Microscopy[C]// Abstract Book of The 16th National Optical Testing Academic Exchange Conference, Shanghai, 2016: 28.
- [14] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning Representations by Back-Propagating Errors[J]. Nature, 1986, 323(6088): 533-536.
- [15] NOBUYUKI O. A Threshold Selection Method from Gray-Level Histograms[J]. IEEE Transactions on Systems, Man, and Cybernetics, 1979, 9(1): 62-66.
- [16] PHANSALKAR N, MORE S, SABALE A, et al. Adaptive Local Thresholding for Detection of Nuclei in Diversity Stained Cytology Images[C]// 2011 International Conference on Communications and Signal Processing, IEEE, 2011: 218-220.