

## 盖板玻璃外观检测的高光谱线扫成像方法

沈冠廷<sup>1</sup>, 饶可奕<sup>1</sup>, 方瑞欣<sup>1</sup>, 张学敏<sup>1</sup>, 巫兆聪<sup>1, 2\*</sup>

1. 武汉大学遥感信息工程学院, 湖北 武汉 430072

2. 河南省科学院空天信息研究所, 河南 郑州 450046

**摘要** 玻璃盖板是智能终端产品的重要组成配件, 表面光滑且透明, 其外观检测是光学成像检测领域的重要难题之一。目前, 常规检测方法主要基于可见光影像, 但是由于纹理相似性, 常将污渍误判为瑕疵, 导致将良品被判定为次品, 从而增加工业成本。为了克服上述问题, 提出基于高光谱技术的盖板玻璃污渍瑕疵检测方法。该方法通过对采集的高光谱数据进行最优特征光谱选择和建立定量检测模型, 挑选出关键特征波段并实现对污渍瑕疵的精确检测。利用油墨区和 AA 透明区的光学特性, 采用线性光源透射的成像方式, 通过专业高光谱线扫设备, 有效采集 50 个手机盖板玻璃高光谱影像, 制作了包括无污无瑕盖板样本 500 个, 及玻璃指纹、胶质物质、清洁剂、灰尘等 4 种污渍和划痕瑕疵样本各 100 个污渍瑕疵的数据集。基于上述高光谱影像数据集, 构建了一种综合考虑污渍瑕疵的光谱特性和各个特征波段的贡献率与重要性的波段选择方法, 精选出可有效区分污渍与瑕疵的 8 个特征波段(502、526、567、689、711、789、818 和 888 nm)。利用机器学习算法进行检测, 实验结果表明, 8 个精选高光谱波段对区分污渍瑕疵具有良好的效果, 准确率达 95.4%, 误分率仅为 4.7%。高光谱影像能捕捉瑕疵和污渍在光谱上的差异, 实现更精确地检测, 为手机盖板玻璃质量检测提供了一种可行的新方法, 可为实际应用中设计低成本高光谱瑕疵污渍检测相机提供参考。

**关键词** 高光谱技术; 污渍瑕疵检测; 特征波段选择; 随机森林算法

**中图分类号**: O433.4

**文献标识码**: A

**DOI**: 10.3964/j.issn.1000-0593(2025)03-0616-07

### 引言

盖板玻璃(Cover Glass), 简称 CG 盖板, 是 3C 显示行业中确保图像质量和触摸响应的关键组件之一, 广泛应用于消费电子、汽车中控屏、工业控制等领域, 其市场需求在近年来不断扩大<sup>[1-2]</sup>。在实际工厂生产环节中, 外观检测需要确保玻璃盖板上没有任何瑕疵。但是, 检测过程常常会把可擦除污渍识别为实质性缺陷, 造成合格玻璃盖板的误判, 增加工业生产成本。因此, 在玻璃盖板中准确识别污渍并且清除也成为外观检测的重要环节。

20 世纪 80 年代的浮法玻璃缺陷检测方法通过分析可见光通过纯净玻璃、玻璃缺陷和玻璃表面杂物等不同物质后得到的不同光反应特点来完成玻璃缺陷类型检测<sup>[3]</sup>, 虽然技术成熟, 但是检测设备存在体积庞大、消耗大、成本高等缺点。

随着机器视觉理论方法和数字图像处理分析技术的成熟, 机器自动化设备逐渐代替人工对各类产品进行表面缺陷

检测。但是, 目前手机盖板玻璃的外观检测策略仍主要集中在缺陷提取算法上<sup>[4-7]</sup>。缺陷提取算法主要是通过使用不同的滤波器和图像相减法来去除干扰, 典型的滤波方法有主成分分析(PCA), 离散余弦变换(DCT), 傅里叶变换(FFT)和小波变换(WT)等<sup>[8-9]</sup>, Li 等<sup>[10]</sup>使用 PCA 来提取缺陷特征。Tsai<sup>[11]</sup>等利用了傅里叶变换 FFT 来检测表面的细小缺陷, 虽然检测精度较高, 但是由于实际生产线上的缺陷种类形态多, 污渍和瑕疵的分类还是易混淆。

随着大数据和计算能力的提升, 基于深度学习的手机盖板玻璃缺陷检测方法紧跟其后, 李伟朝等<sup>[12]</sup>提出基于 PU-Faster R-CNN 的手机屏幕缺陷检测。伍济钢<sup>[13]</sup>面向智能手机玻璃盖板缺陷检测的 YOLOv3 改进和应用, 增加了神经网络通道注意力机制解决特征不明显问题。吴闯<sup>[14]</sup>基于深度卷积神经网络的手机玻璃盖板表面缺陷分类检测研究, 将卷积神经网络结合迁移学习的 SE 模块做检测。虽然基于机器视觉和深度学习的缺陷检测技术有不少研究, 但是由于都是依赖于光学图像做识别, 污渍和瑕疵的几何外观的相似性容

收稿日期: 2023-11-14, 修订日期: 2024-07-03

基金项目: 河南省科学院科研启动经费项目(242025005), 国家重大科研仪器研制项目(11727806)资助

作者简介: 沈冠廷, 1999 年生, 武汉大学遥感信息工程学院硕士研究生 e-mail: 2017312590088@whu.edu.cn

\* 通讯作者 e-mail: zcwoo@whu.edu.cn

易导致误检，因此这些方法在实际应用中检测效果不佳。

针对基于可见光影像的盖板玻璃外观检测难以精准识别污渍瑕疵的问题，开展基于高光谱线扫成像技术的盖板玻璃外观检测研究。利用化学物质和物理损伤在精细光谱特性上的差异，采用高光谱技术捕捉污渍与瑕疵之间显著不同的特征光谱，从而实现盖板玻璃的污渍和瑕疵检测，解决了传统可见光影像中由于污渍和瑕疵纹理相似而导致检测效果不佳的问题。

1 实验部分

1.1 高光谱反射率数据集构建

高光谱成像技术是指在电磁波谱范围内获取许多非常窄的光谱连续的影像数据，通过精细光谱来研究光与物质之间的相互作用，可以探知物质的物理化学特性。采集手机盖板玻璃的高光谱影像，捕捉污渍和瑕疵在特征光谱上的差异进行外观检测。

50 个手机盖板玻璃样本统一由盖板玻璃制造公司提供，盖板样本上由专业人员制作了玻璃指纹、胶质物质、清洁剂、灰尘等 4 种污渍和划痕瑕疵。高光谱数据通过高光谱成

像仪 (Hyperspec VNIR-SWIR with Co-Registered pixels) 采集具有高光谱共记录特性的像素，光谱测量范围为 400 ~ 1 000 nm，光谱分辨率为 5 nm，空间分辨率为 0.3，光谱通道数 369，空间通道数 1 600。

盖板玻璃由玻璃材质制成，AOI 光学成像检测需要在强光照射下进行识别。如图 1 所示，利用两台卤素灯作为光源，并获取最佳光线入射角度以增强成像清晰度。通过调整两盏卤素灯使入射光与手机盖板玻璃平面的夹角为 30°、45°、60° 和 90°，成像结果如图 2 所示。



图 1 数据采集实验装置

Fig. 1 Data collection experimental device




图 2 (a)30°; (b)45°; (c)60°; (d); 90°; (e)标准光源

Fig. 2 (a) 30°; (b) 45°; (c) 60°; (d) 90°; (e) Standard light source

除了图像评价以外，还以结构相似性指数 (SSIM) 和峰值信噪比 (PSNR) 两个清晰度评价指标综合亮度、对比度和结构信息评价成像清晰度，PSNR 计算公式如式 (1) 和式 (2) 所示，SSIM 计算公式如式 (3) 所示。

MSE = \frac{1}{N} \sum\_{i=1}^N (I\_i - K\_i)^2 \tag{1}

式 (1) 中， $N$  是像素总数， $I_i$  和  $K_i$  分别表示两幅影像在相应位置  $i$  的像素值。该公式表示对每个像素位置上的差异进行平方，然后将所有平方差值相加并除以像素总数，得到 MSE 值。

PSNR = 10 \times \log\_{10} \frac{\max^2}{MSE} \tag{2}

式 (2) 中， $\max$  是图像中可能出现的最大像素值，对应于 8 位图像为 255，均方误差 (MSE) 表示原始图像和待比较图像之间每个像素值差异的平方平均值。PSNR 的结果以分贝 (dB) 为单位，提供了一种对图像质量的直观度量，较高的 PSNR 值表示图像质量较好。

SSIM = \frac{(2u\_x u\_y + c\_1)(2\sigma\_{xy} + c\_2)}{(u\_x^2 + u\_y^2 + c\_1)(\sigma\_x^2 + \sigma\_y^2 + c\_2)} \tag{3}

式 (3) 中， $u_x$  和  $u_y$  分别表示图像  $x$  和  $y$  的亮度均值， $\sigma_x^2$  和  $\sigma_y^2$  分别表示图像  $x$  和  $y$  的方差， $\sigma_{xy}$  表示图像  $x$  和  $y$  之间的协方差， $c_1$  和  $c_2$  为常数，为了避免分母为 0，较高的 SSIM 值表示图像质量较好。最终结果如表 1 所示。基于定性和定量结果显示光的入射角为 45° 时对于污渍瑕疵的成像效果最清晰。

表 1 不同光入射角的成像清晰度  
Table 1 Imaging clarities of stain defects under different incident angles

光入射角	SSIM	PSNR	清晰度
30°	0.912	28.24	较为清晰
45°	0.932	31.38	很清晰
60°	0.922	31.29	较为清晰
90°	0.919	28.89	不清晰

对采集到的高光谱影像进行辐射校正与反射率计算。在固定光源和成像目标之间的观测几何条件后，采集一张已知

反射率的标准白板的高光谱影像。基于辐射定标系数,将像素的 DN 值转换为辐亮度影像,即点光源的光照强度。

将以黑色纸板为背景的盖板玻璃样本放置于固定白板前,进行高光谱数据采集,以使得盖板玻璃在对应点上接收到与原始白板完全相同的光源照射,在此基础上将手机盖板玻璃的辐亮度影像与白板的辐亮度影像做比值处理,计算得到整幅手机盖板玻璃影像的光谱反射率。

基于以上步骤,有效采集 50 个手机盖板玻璃高光谱影像。光谱数据在采集过程中受到实验环境、测量仪器、实验操作以及样本本身质量的影响,400~500 和 900~1 000 nm 范围内的影像信噪比较低,无法使用,被剔除;得到 500~900 nm 光谱范围的 246 个波段的光谱曲线,采用 SG 滤波进行平滑处理,以消除随机噪声、基线偏移的影响。最后,以 66 窗口大小作为感兴趣区(AOI)构建高光谱反射率样本集,取窗口区域内反射率均值作为该样本类型的典型光谱反射率,制作了包括无污无瑕盖板样本 500 个,及玻璃指纹、胶质物质、清洁剂、灰尘等 4 种污渍和划痕瑕疵样本各 100 个的污渍瑕疵数据集,共计 1 000 个样本,样例如图 3 所示。




图 3 (a)手机盖板;(b)划痕;(c);胶质物质;(d)指纹;(e)灰尘;(f)清洁剂

Fig. 3 (a) Phone cover glass; (b) Scratches; (c) Glial substances; (d) Fingerprints; (e) Dust; (f) Cleaning agents

## 1.2 污渍瑕疵的光谱特性分析

为了更好的选择区分污渍瑕疵的特征波段,先对比分析污渍和瑕疵的光谱特性。如图 4 所示,四类污渍的光谱曲线与盖板的光谱曲线略有不同,反射率都高于盖板反射率。光谱曲线形状的差异是由于不同污渍材质不同会在不同波段出现特征吸收峰使得曲线形状有些差异,而差异不明显的原因则是污渍的含量过少。几种污渍反射率都高于盖板反射率的原因是污渍受到光反射后会形成亮斑,由于亮度上的差异使得污渍反射率都高于盖板。

胶质物质污渍是手机盖板玻璃在传送带运输过程中,由于传送带老化或环境温度影响与玻璃接触摩擦后残留的痕迹,主要成分为聚氨酯、聚酯和硅胶等。胶质物质在 590~610、680~700 和 780~810 nm 附近有微弱吸收峰。这些吸收峰由于胶质物质含量较少,仅在玻璃表面形成薄薄一层,

因此不明显。

灰尘是指玻璃盖板在生产过程中,空气中的尘埃颗粒落在玻璃上形成的污渍,主要成分为油脂、煤尘和材料碎片等。灰尘在 500~520 和 700~730 nm 附近有微弱吸收峰。这些吸收峰由于灰尘含有金属粉尘和其他材料粉尘化学物质,且灰尘量少、附着层薄,因此不明显。




图 4 污渍瑕疵反射光谱

Fig. 4 Reflectance spectra of stains and defects

指纹是手机盖板玻璃上常见的污渍之一,由手指或手掌上的油脂、汗液和微小颗粒混合物形成,通常在操作过程中接触盖板时留下。指纹的主要成分为有机物、脂肪酸和氨基酸等。指纹在 500~520 和 550~580 nm 附近有微弱吸收峰,这些吸收峰由于含有油脂、氨基酸、蛋白质及工厂环境中的化学物质,且指纹量少、附着层薄,因此不明显。

清洁剂是手机盖板玻璃生产过程中常见的残留污渍,通常由于清洁不当或控制不严而残留在玻璃表面。清洁剂主要成分包括醇类、酮类和醚类等有机化合物。清洁剂在 500~520、600~630、680~700 和 810~840 nm 附近有微弱吸收峰。这些吸收峰是由于清洁剂的残留,其用量、工厂环境条件(如温度和湿度)及清洁剂的挥发性所导致。

手机盖板玻璃的瑕疵指的是玻璃盖板在生产的工艺环节中,由于生产技术、工厂环境和人为原因等因素而使得玻璃产生的划痕、斑点、崩边、擦伤等等对玻璃盖板物理结构上的破坏,在影像上显示为亮斑亮点。在光谱特性方面,瑕疵的反射率在 500~900 nm 范围呈现下降趋势,通过对比瑕疵和污渍在 500~900 nm 范围的光谱曲线,瑕疵并没有类似污渍的吸收峰存在,这是因为瑕疵是手机盖板玻璃物理结构的破坏,本质还是盖板并无其他物质,因此其光谱曲线形状与盖板相似。

## 1.3 基于特征递归消除法的特征波段选择

为了选择出能区分污渍瑕疵的特征波段,采用决策树和随机森林(random forest, RF)两种模型的特征递归消除法作波段选择,它通过反复训练模型,并剔除其中的弱特征,直到达到所需的特征数量。决策树的特征选择能力使其能够识别最重要的特征,从而降低了维度灾难的影响;同时随机森



林算法也是一种基于决策树的集成学习方法，其模型同样具有较好的稳定性和可解释性，同时对两个模型都采用五折交叉验证来最大程度利用数据以及减少过拟合的风险。首先，对全波段进行波段选择，统计十次重要性排序以及各波段贡献率，剔除贡献率过低的波段并统计精确率、召回率和 F1 分数。随后对第一次波段选择后的特征波段进行第二次的波段选择，再次统计十次重要性排序以及各波段的贡献率，经过统计将贡献率低的无用波段去除，得到第二次特征选择波段的结果以及精确率、召回率和 F1 分数。最后进行第三次五折交叉验证的波段选择，再次精简波段，通过依次删除贡献率低的波段，比较互相之间精确率、召回率以及 F1 分数，综合考虑波段数量以及精度的要求，由于随机森林模型的精度优于决策树，因此最终确定基于随机森林模型的特征递归消除法作为特征波段选择结果。

1.4 基于机器学习的瑕疵污渍分类方法

为了进一步优化模型性能、降低成本和减少冗余信息，提出了精选特征波段的方法。该方法基于光谱特性分析，逐个剔除粗选的特征波段中不在特征吸收峰范围内的波段。这一逐步剔除的过程确保了最终选择的特征波段集合与污渍的吸收特性高度匹配，最终得到了精选后的波段，随后将其输入三种分类器：随机森林、XGBoost 和 AdaBoost. M2 进行模型训练，以精确率、准确率和 F1 分数评价指标来评断不同特征波段数量的精度，同时验证剔除波段的冗余性。其中，XGBoost 和 AdaBoost. M2 同属于 boosting 算法，XGBoost 是一种梯度提升树(Gradient Boosting Tree)算法，它通过集成多个决策树来提升分类性能；AdaBoost. M2 是 AdaBoost 算法的一种改进版本，通过改变样本权重的更新方式，提高了算法的鲁棒性和性能。最终通过对比分析比较不同波段组合下在三个分类器的分类精度，最终确定最优的特征波段个数为 8 个以及分类性能最佳的分类器为随机森林。

2 结果与讨论

2.1 污渍瑕疵分类的最优特征波段

经过第一次基于随机森林的特征递归消除法，如表 2 所示，选出的特征波长分别是 502、526、567、689、711、779、789、818、828、836、838、844、847、864、873、888 和 891 nm 一共 17 个波长。随后，再次运用五折交叉验证随机森林对第一次选择的 17 个波段进行分类，统计十次重要性排序以及各波段贡献率，由于 836、847、873 和 891 nm 波段贡献率都不足 5%，因此剔除这四个波段，第二次波段选择的结果一共是 13 个波段，他们分别是 502、526、567、689、711、779、789、818、828、838、844、864 和 888 nm，用 17 个特征波段进行分类的召回率、精确率和 F1 分数分别为 0.785、0.795、0.776。再次运用五折交叉验证决策树对第二次波段选择的 13 个波段进行分类，统计十次重要性排序以及各波段贡献率，剔除贡献率低于 10% 的波段，即去除 828、838 和 864 nm，用 13 个特征波段进行分类的召回率、精确率和 F1 分数分别为 0.802、0.806、0.798。第三次特征递归去除后得到的波段一共是 10 个波段，他们分别 502、526、567、689、

711、779、789、818、844 和 888 nm。用 10 个特征波段进行分类的召回率、精确率和 F1 分数为 0.817、0.818 和 0.804。经过精度的比较以及贡献率重要性的排名，这 10 个波段的贡献率相差不大，因此最终确认将经由随机森林特征波段选择的 10 个波段作为分类污渍瑕疵的粗选特征波段。

表 2 随机森林不同波段数的分类精度结果  
Table 2 Classification accuracy results of random forest with different bands

特征波长/nm	召回率	精确率	F1 分数
全波段	0.762	0.771	0.753
502、526、567、689、711、779、789、818、828、836、838、844、847、864、873、888、891	0.785	0.795	0.776
502、526、567、689、711、779、789、818、828、838、844、864、888	0.802	0.806	0.798
502、526、567、689、711、779、789、818、844、888	0.817	0.818	0.804

为了进一步优化模型性能、降低成本和减少冗余信息，提出了精选特征波段的方法。该方法基于光谱特性分析，逐个剔除粗选的 10 个特征波段中不在特征吸收峰范围内的波段。这一逐步剔除的过程确保了最终选择的特征波段集合与污渍的吸收特性高度匹配，最终得到了各自精选后的 9 和 8 波段，具体情况如表 3 所示。而对于随机森林模型，RF-10 到 RF-9 剔除的波段是 779 nm，这是由于 779 nm 在吸收峰波段的范围边缘，因此剔除；RF-9 到 RF-8 剔除的波段是 844 nm，同样是由于该波段在吸收峰波段的范围边缘。然而，当进一步减少到 7 个特征波段时，无论是去除任一波段，准确率和精确率再次下降，这可能表明剔除了过多的波段，导致丢失了一些重要信息，从而影响了分类性能的提升。

表 3 随机森林特征波段  
Table 3 Random forest feature bands

波段数量	波段/nm
10	502、526、567、689、711、779、789、818、844、888
9	502、526、567、689、711、789、818、844、888
8	502、526、567、689、711、789、818、888

将经过随机森林波段选择后的 10 个波段，以及经过光谱特性分析去除冗余波段后的 9、8 和 7 个特征波段组分别带入训练好的随机森林模型、XGBoost 和 AdaBoost. M2 三个模型进行分类，并用精确率和准确率评价指标评定，结果如表 4 所示，从横向角度分析三个分类器对于同种特征递归模型的精度结果，随机森林、XGBoost 和 AdaBoost. M2 三个分类器展示的精度趋势同样较为相似，即当波段数量从 10 降低到 8 的过程中，准确率和精确率都呈现上升趋势，然而将波段数量进一步降低时，去除任一波段得到精度都是下降，因此将随机森林模型的波段组精选至 8 波段时最佳。对于分类效果而言，随机森林分类器在同波段数量下的分类精确都是最佳，当波段数量为 8 时精度最高，其精确率与准确

率分别为 0.831 和 0.886。AdaBoost. M2 分类器的精度略低于随机森林, 而 XGBoost 的分类精度最低。总体来说, 对比全部精度, 当分类器是随机森林, 精选波段数量为 8 时效果最佳, 准确率和精确率分别为 0.886 和 0.831。因此综合来

看, 随机森林分类器表现出较好的稳定性和性能, 可作为首选的分类器; 而基于随机森林特征递归模型精选的 8 个特征波段也展示最佳的精度结果, 因此 502、526、567、689、711、789、818 和 888 nm 为最终精选的波段。

表 4 精度对比  
Table 4 Accuracy comparison

	RF				XGBoost				AdaBoost. M2			
	10	9	8	7	10	9	8	7	10	9	8	7
精确率	0.809	0.815	0.831	0.804	0.716	0.730	0.742	0.711	0.792	0.803	0.803	0.798
准确率	0.873	0.876	0.886	0.868	0.804	0.813	0.825	0.803	0.865	0.869	0.873	0.865

2.2 污渍瑕疵分类结果

在确认了随机森林作为分类器, 并确定了包含 8 个精选特征波段后, 接下来对这些特征波段在随机森林分类器中的性能进行全面评估。检测的最终目标是为了分类污渍和瑕疵, 但是直接按污渍和瑕疵两类进行分类, 从高光谱分类角度来说并不合理, 因此采取先细分类再进行类别合并的策略。下面进行分类结果图的细节分析, 如图 5 所示。




图 5 污渍瑕疵分类结果图

Fig. 5 Classification result chart of stains and defects

首先, 观察图 5(a)及其分类结果图, 即使在划痕覆盖了部分污渍的情况下, 分类器仍能够较好地划痕和污渍分开。此外, 即使污渍在目视上不太明显的区域, 分类器也能

够准确地将污渍区域与盖板区域区分开来。对于图 5(b)及其分类图, 分类器能够有效地区分划痕和污渍, 且在污渍和盖板之间也具有较好的区分度。这表明分类器在处理具有一定复杂度的情况下, 仍能够取得较好的分类效果。最后, 对于图 5(c)及其分类图, 分类器同样能够准确地将划痕和污渍区分开, 并且在污渍和盖板之间也呈现出明显的区分度。

2.3 污渍瑕疵检测精度

统计精度后的结果在表 5 中呈现, 基于 8 个特征波段的污渍瑕疵分类展现出了显著的提升。准确率、精确率、召回率、F1 分数、错分误差和漏分误差分别达到了 0.954、0.952、0.922、0.937 和 0.047 和 0.078。相较之下, 全波段污渍瑕疵的准确率、精确率、召回率、F1 分数、错分误差和漏分误差分别为 0.939、0.923、0.897、0.910、0.076 和 0.103。基于 8 个特征波段的模型在准确率、精确率、召回率和 F1 分数上均超越了全波段的模型, 其中准确率上升了 1.5%, 精确率上升了 2.9%, 错分误差下降了 2.9%, 漏分误差下降了 2.5%。这一结果表明实验成功地实现了对波段的降维, 从原本的 246 波段中挑选出的 8 个特征波段在污渍瑕疵分类中表现更为出色, 同时说明通过细致的光谱特性分析和特征波段的挑选成功地提升了分类性能。这一成功的案例也强调了在面对分类困难且复杂的问题时, 通过分步骤的分析和特征选择, 结合合适的策略进行分类任务的优化是非常有效的。综上所述, 研究所提出的 8 个特征波段结合随机森林分类器跑够有效地区分手机盖板玻璃的污渍和瑕疵, 为手机盖板玻璃质量检测提供了可靠的技术支持。

表 5 污渍瑕疵分类精度  
Table 5 Classification accuracy of stains and defects

类别	波段数	平均误差	准确率	精确率	召回率	F1 分数	错分误差	漏分误差
污渍、瑕疵和盖板	8	0.046	0.954	0.952	0.922	0.937	0.047	0.078
污渍、瑕疵和盖板	246	0.060	0.939	0.923	0.897	0.910	0.076	0.103

3 结 论

结合高光谱技术以及随机森林方法为手机盖板玻璃污渍瑕疵的识别提供新的方法途径。利用高光谱遥感技术获取污渍在大量窄带光谱范围内的光谱信息, 准确捕捉瑕疵和污渍

的形态特征, 再针对高光谱数据特点, 提出基于随机森林的特征波段选择方法, 并根据分类器精度精选特征波段用于分类, 最终精选 8 个特征波段作为分类波段以及确认了随机森林作为分类器。

(1)通过胶质物质、指纹、清洁剂、灰尘和划痕光谱曲线与盖板光谱曲线特征的不同分析了不同污渍瑕疵的光谱特性

及其各自成分对盖板光谱特征的影响。采集了污渍的光谱曲线并进行了分析,结果表明胶质物质在 590~610、680~700 和 780~810 nm 出现吸收谷,指纹在 500~520、550~570 nm 出现吸收谷,灰尘在 500~520 和 700~730 nm 出现吸收谷,清洁剂在 500~520、600~630、680~700 和 810~840 nm 出现吸收谷。

(2)通过基于随机森林的特征递归消除法,对全波段进行逐步筛选,以发现与污渍瑕疵高度相关的特征波段。经过逐步去除低贡献率波段,最终粗选了 10 个特征波段,分别是 502、526、567、689、711、779、789、818、844 和 888 nm。证

明原始高光谱数据存在大量冗余信息,将选择后的波段用于分类也更符合现实工业需求。

(3)使用随机森林、XGBoost 和 AdaBoost.M2 三种分类器对手机盖板玻璃污渍瑕疵进行分类实验,进一步精选特征波段,确认最佳特征波段数量为 8 个:502、526、567、689、711、789、818 和 888 nm,以及最佳分类效果的分类器为随机森林。随后根据实际应用把四类污渍类别合并,得到 8 个特征波段获得的分类识别的准确率、精确率、召回率、F1 分数、错分误差和漏分误差分别为 0.954、0.952、0.922、0.937 和 0.047 和 0.078。

## References

- [1] CUI Yan, PENG Ke, YANG Yu-e, et al(崔焱,彭可,杨玉娥,等). Manufacturing Automation(制造业自动化), 2023, 45(7): 75.
- [2] HE Yi-lin, TAO Xiao(贺旖琳,陶肖). Industrial Control Computer(工业控制计算机), 2022, 35(12): 74.
- [3] Latham V H, Nixon M S, Mayers C. Glass Technology, 1986, 27: 188.
- [4] Li C, Zhang X, Huang Y, et al. Computers & Industrial Engineering, 2020, 146: 106530.
- [5] ZHANG Jian-guo, LI Ying, QI Jia-kun, et al(张建国,李颖,齐家坤,等). Journal of Applied Optics(应用光学), 2020, 41(5): 984.
- [6] Jian C X, Gao J, Ao Y H. Applied Soft Computing, 2017, 52: 348.
- [7] LUO Gen, NI Jun(罗根,倪军). Journal of Electronic Measurement and Instrumentation(电子测量与仪器学报), 2018, 32(2): 92.
- [8] Takhar G, Prakash C, Mittal N, et al. Comparative Analysis of Background Subtraction Techniques and Application, International Conference on Recent Advances & Innovations in Engineering IEEE, 2017.
- [9] Zhang Z, Xu Y, Yang J, et al. IEEE Access, 2015, 3: 490.
- [10] Li D, Liang L Q, Zhang W J, et al. The International Journal of Advanced Manufacturing Technology, 2014, 73(9): 1605.
- [11] Tsai D M, Tseng Y H, Fan S K M. Defect Inspection of Liquid-Crystal-Display (LCD) Panels in Repetitive Pattern Images Using 2D Fourier Image Reconstruction, International Conference on Autonomic and Autonomous Systems, 2018.
- [12] LI Wei-chao, CHEN Zhi-hao, ZHANG Xie, et al(李伟朝,陈志豪,张颢,等). Computer Measurement & Control(计算机测量与控制), 2023, 31(7): 99.
- [13] WU Ji-gang, CHENG Yuan, SHAO Jun, et al(伍济钢,成远,邵俊,等). Chinese Journal of Liquid Crystals and Displays(液晶与显示), 2021, 36(12): 1728.
- [14] WU Chuang, YU Da-yong(吴闯,于大泳). Software Engineering(软件工程), 2021, 24(12): 6.

## A Method for Classifying Stains and Defects on Mobile Phone Cover Glass Based on Hyperspectral Line Scan Imaging

SHEN Guan-ting<sup>1</sup>, RAO Ke-yi<sup>1</sup>, FANG Rui-xin<sup>1</sup>, ZHANG Xue-min<sup>1</sup>, WU Zhao-cong<sup>1, 2\*</sup>

1. School of Remote Sensing Information Engineering, Wuhan University, Wuhan 430072, China

2. Aerospace Information Research Institute, Henan Academy of Sciences, Zhengzhou 450046, China

**Abstract** Cover glass is an important component of intelligent terminal products, with a smooth, transparent surface and complex and variable characteristics. Its appearance inspection is one of the important challenges in optical imaging detection. Currently, conventional detection methods are mainly based on visible light images. Still, due to texture similarity, stains are often misjudged as defects, making good products judged as defective, thereby increasing industrial costs. To overcome the above problems, this article proposes a method for detecting stains and defects on cover glass based on hyperspectral technology. This method selects the hyperspectral data's optimal feature spectrum and establishes a quantitative detection model to select key feature bands and accurately detect stains and defects. This article utilizes the optical properties of the ink and AA transparent areas and adopts a linear light source transmission imaging method. Through professional hyperspectral line scanning equipment, 50 hyperspectral images of mobile phone cover glass were effectively collected. A stain defect dataset was created, including 500 samples of clean and flawless cover plates and 100 samples of four types of stains and scratch defects, including glass fingerprints, adhesive substances, cleaning agents, and dust. Based on the above hyperspectral image dataset, this paper

constructs a band selection method that comprehensively considers the spectral characteristics of stains and defects and the contribution and importance of each feature band. Eight feature bands (502, 526, 567, 689, 711, 789, 818, and 888 nm) that can effectively distinguish stains and defects are selected. Using machine learning algorithms for detection, experimental results show that 8 selected hyperspectral bands perform well in distinguishing stains and defects, with an accuracy rate of 95.4% and an error rate of only 4.7%. Hyperspectral imaging can capture the differences between defects and stains in the spectrum, achieving more accurate detection and providing a feasible new method for quality inspection of mobile phone cover glass. It can provide a reference for designing low-cost hyperspectral defect and stain detection cameras in practical applications.

**Keywords** Hyperspectral; Stain defect detection; Feature band selection; Random forest

(Received Nov. 14, 2023; accepted Jul. 3, 2024)

\* Corresponding author