

基于拓展型特征金字塔的 OLED 像素缺陷检测方法

刘兰¹, 叶芸^{1,2*}, 郭太良^{1,2}

¹福州大学物理与信息工程学院, 福建 福州 350100;

²中国福建光电信息科学与技术创新实验室, 福建 福州 350100

摘要 针对传统方式检测有机发光二极管(OLED)像素缺陷精度低以及成本高的问题,提出了一种基于拓展型特征金字塔网络(FPN)的喷墨打印OLED像素缺陷检测方法。首先对数据进行处理,获得喷墨打印OLED像素图像数据集,随后利用预训练模型ResNet18作为主干,选取其底层模块作为特征提取器,制定出更加适合打印像素缺陷的训练网络。通过将FPN进行拓展,使用具有丰富区域细节的大规模超分辨率特征来解耦像素缺陷检测,实现缺陷区域信息的获取与缺陷的像素级分割。实验中对比了不同方法在OLED像素数据集上的检测效果并评估了不同方法在几个缺陷类型上的性能。结果表明:所提出的方法对喷墨打印OLED像素缺陷的识别精度比直接使用FPN提升了5.5%(达到99.8%),对缺陷区域的分割平均精度提升3.7%(达到88.8%),且所提模型适用于小样本缺陷数据检测,具有研究价值和实践意义。

关键词 测量;有机发光二极管;喷墨打印;缺陷检测;特征金字塔;缺陷分割

中图分类号 TP391.4 文献标志码 A

DOI: 10.3788/AOS221411

1 引言

采用喷墨打印技术制备有机发光二极管(OLED)显示屏是下一代显示技术的研究方向。该技术是一种材料节约型沉积技术,具有工艺简单、低成本、低功耗和可大面积生产等特点,已广泛应用于电子行业^[1-3]。喷墨打印过程对工艺参数的精确性要求极其严格,参数在误差范围之外时容易造成打印缺陷。在制程中,OLED打印像素图像由重复的、等间距的水平和垂直线条组成,这种背景纹理随照明条件的变化而变化,纹理的变化、缺陷像素的低对比度和缺陷区域的变化尺寸给这些缺陷的检测带来了巨大的挑战。可能的打印缺陷主要分两大类:OLED打印像素成膜完整性缺陷和OLED打印像素成膜厚度均匀性缺陷。其中成膜完整性缺陷包括:存在卫星点、未打满bank、过大墨滴溢出bank、多缺陷混合等^[4]。

自动光学检测技术(AOI)在OLED的缺陷检测上得到了广泛应用^[5]。汪志亮等^[6]提出了一种基于多次迭代差影法的OLED屏像素缺陷检测方法,该方法可以较准确地实现显示屏点缺陷的检测,但由于FastICA是一个自适应算法,用它计算得到的解混矩阵在图片背景重构时还不够稳定;利用面板像素周期

性排布的方法^[7]更加易于实现对OLED屏的缺陷检测,通过阈值筛选出真正的缺陷,但未考虑复杂背景下的点线缺陷,容易漏检;简川霞等^[8]使用模糊C均值聚类对OLED显示屏模糊边界的缺陷区域进行分割,该方法对样本量非常敏感,这限制了其在实际生产中的应用。Kwak等^[9]通过图像处理的方法对OLED面板中的椒盐缺陷进行检测;Sindagi等^[10]使用一种用于离群点检测的域自适应SVDD(support vector data description)对面板缺陷进行检测;文献[11-14]针对Mura缺陷、模块边缘裂纹、OLED显示器物理缺陷等提出多种缺陷检测算法,主要方法有区域学习、无监督对抗学习Res-unetGAN、度量学习、小波变换等。现存的大多数方法在OLED面板表面缺陷检测上取得了不错的效果,但是对于OLED打印像素缺陷来说,这些方法容易忽略其细节特征。一般情况下,200 mm×200 mm的OLED喷墨打印OLED面板点阵内像素尺寸为58 μm×164 μm,其缺陷尺寸小于0.01 mm²,上述方法在有限的打印像素图像以及非常微小的像素缺陷条件下存在一定的局限性,无法在OLED打印像素图像质量降低的同时对像素缺陷有比较好的检测效果。

本文立足于OLED像素缺陷目标难以识别的特

收稿日期: 2022-07-04; 修回日期: 2022-07-16; 录用日期: 2022-07-25; 网络首发日期: 2022-08-05

基金项目: 国家重点研发计划(2021YFB3600404)、福建省科技厅重大专项项目(2021HZ021001)、福建省自然科学基金(2022J01130129)、中国福建光电信息科学与技术创新实验室项目(2020ZZ112)

通信作者: *yeyun07@fzu.edu.cn

性,提出一种拓展型特征金字塔网络(FPN),将其运用在 OLED 像素缺陷检测任务中,首先通过融合不同级别的特征金字塔来增强特征。为了提升 OLED 像素缺陷检测的灵敏性,增加了专用的小目标特征提取模块,然后使用一个额外的高分辨率金字塔层来提取可信的区域细节,通过将最底层两个金字塔层融合,减小通道容量,充分利用底层特征图的信息;最后针对样本数据不足造成的低拟合度问题,使用迁移学习在有限的样本基础上进行训练。实验结果表明,该方法在保留了 OLED 像素图像大尺度层输出语义信息的同时融入小尺度层输入的细节特征信息,有效提升了 OLED 像素缺陷检测的精度,实现了 OLED 喷墨打印像素缺陷的智能化检测,提高检测的效率和精度,降低检测的成本,从客观上实现检测人员劳动强度的降低,为整个行业自动化水平的提高提供了技术可能性。

2 缺陷像素检测系统及算法

2.1 系统整体结构

喷墨打印 OLED 像素缺陷检测系统整体结构如图 1 所示,主要包括图像预处理、OLED 像素图像缺陷检测两个阶段。首先,对图像进行预处理,将采集得到的 OLED 像素图像进行直方图均衡化,以增强对比度;使用尺度不变特征变换(SIFT)算法对分块图像进

行拼接,实现完整匹配图像的融合;采用翻转变换、随机剪裁、亮度变换等方法增广数据集,防止喷墨打印 OLED 像素样本不足而导致检测模型的检测精度低、拟合度低、鲁棒性差等问题。然后训练网络,将在 ImageNet 上进行过预训练的强大模型 ResNet18 作为主干,引入拓展型 FPN,选取其底层模块作为特征提取器,测试网络与训练网络结构相同,而参数随机化,通过将无异常图像的特征与预训练网络的相应特征相匹配来学习无异常图像的分布,最终完成缺陷像素图像的位置标记、mask 二值掩码图像信息的转换、异常区域信息的获取及预测。

2.2 特征提取与融合

现有的 FPN 中金字塔等级和建议尺寸之间的差异可能会混淆小物体的检测,不同层次的对象需要共享相同的特征图,在多尺度特征空间^[15-16]上随着目标尺度的减小,FPN 底层的检测精度急剧下降。传统的缺陷检测方法需要使用大量数据进行训练,为了应对训练集不足以及 OLED 像素缺陷难以识别的问题,通过嵌入一个类似 FPN 框架的特征抽取模块来实现拓展的 FPN,该结构直接从低分辨率图像生成高分辨率特征,以支持小缺陷检测^[17],采用 ResNet18^[18]和拓展型 FPN^[19]相结合的方式特征提取。图 2 为本文所采用喷墨打印 OLED 像素缺陷检测算法的整体结构。

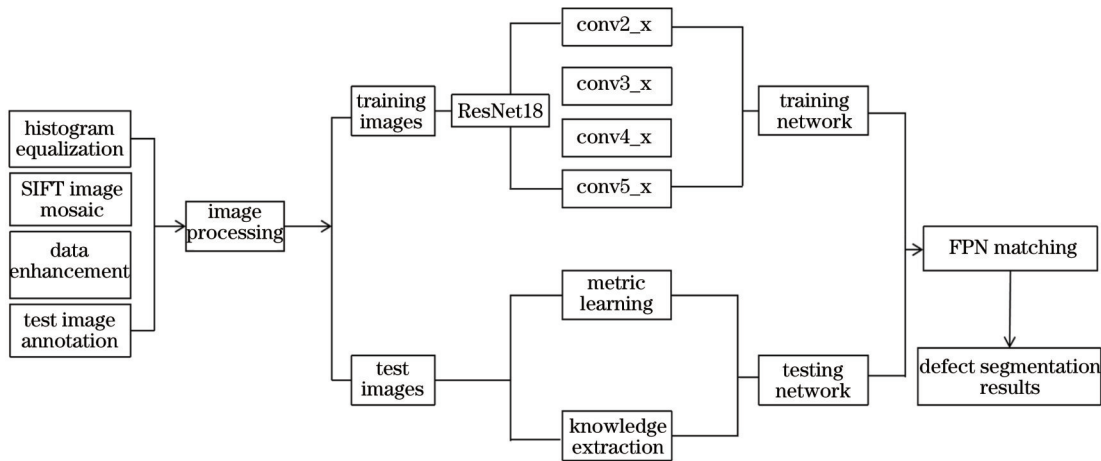


图 1 系统整体结构

Fig. 1 Overall system structure

FPN 拓展部分是将金字塔中的第三、四层在特征模块中融合,以产生具有特定区域信息的中间特征。首先使用内容提取器提取出第三层的主要语义内容;然后通过像素卷积将所得特征层的分辨率进一步提高;随后将所得特征层与第四层特征模块进行融合,使用纹理提取器从主要特征和参考特征的交叉部分选择可信的纹理区域用于小目标的检测;最后连接具有超分辨率内容特征的纹理。FPN 拓展部分结构图如图 3 所示。

2.3 特征分布建模

特征提取的目的是获得一个能够在正常图像上模仿固定输出的模型,给定一个无缺陷图像的训练集 $X = [x_1, x_2, \dots, x_k, \dots, x_n]$, 通过将 L 个底部层提取的特征与测试网络对应的特征进行匹配来捕捉正常数据流形。对于输入的图像 $x_k \in \mathbf{R}^{h \times w \times c}$, 其中 h, w, c 分别代表高度、宽度、通道数,第 l 个底层组输出的训练图像和测试图像的特征图分别是 $F_t^{(l)}(x_k) \in \mathbf{R}^{h^{(l)} \times w^{(l)} \times d^{(l)}}$ 和 $F_s^{(l)}(x_k) \in \mathbf{R}^{h^{(l)} \times w^{(l)} \times d^{(l)}}$, 其中 $h^{(l)}, w^{(l)}, d^{(l)}$ 分别表示特征

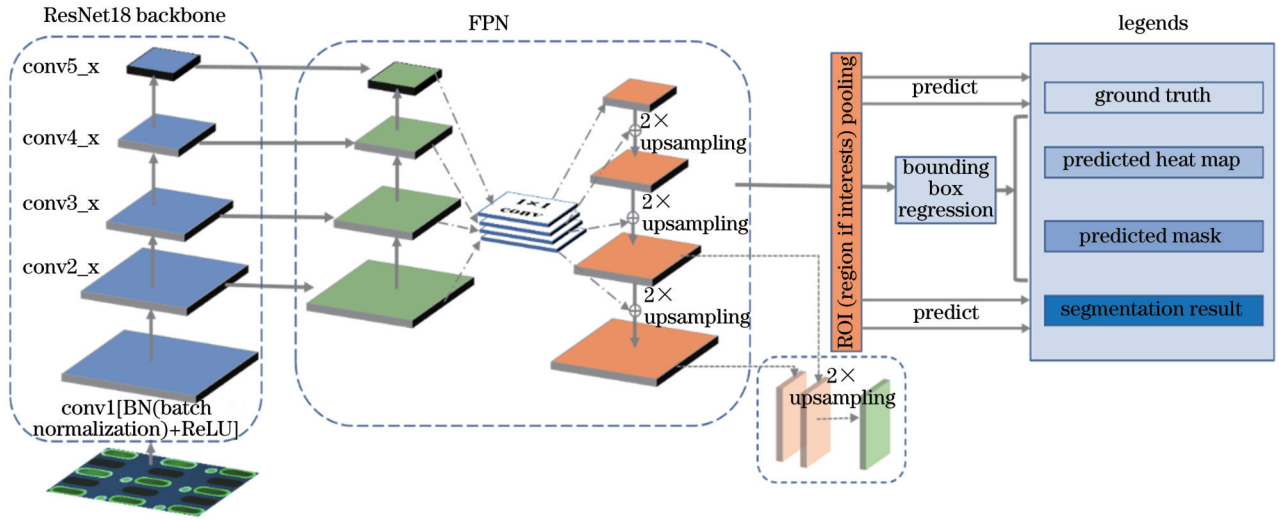


图 2 喷墨打印 OLED 像素缺陷检测算法整体结构

Fig. 2 Overall structure of pixel defect detection algorithm for inkjet printing OLED pixel

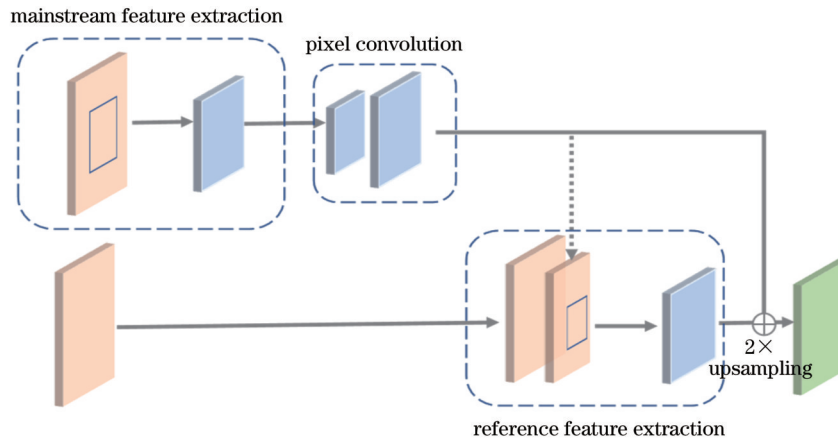


图 3 FPN 拓展部分结构图

Fig. 3 Structure diagram of FPN expansion section

图像的高度、宽度和通道数。 $F_t^{(l)}(x_k)_{ij} \in \mathbf{R}^{d^{(l)}}$ 和 $F_s^{(l)}(x_k)_{ij} \in \mathbf{R}^{d^{(l)}}$ 分别是来自训练网络和测试网络特征图中位置 (i, j) 处的特征向量, $\hat{F}_t^{(l)}(x_k)_{ij}$ 代表位置 (i, j) 处特征向量的单位向量, 本文将位置 (i, j) 处的损耗定义为 ℓ_2 -归一化特征向量之间的距离, 它们之间的关系可表示为

$$\ell^{(l)}(x_k)_{ij} = \frac{1}{2} \|\hat{F}_t^{(l)}(x_k)_{ij} - \hat{F}_s^{(l)}(x_k)_{ij}\|_{\ell_2}^2, \quad (1)$$

$$\hat{F}_t^{(l)}(x_k)_{ij} = \frac{F_t^{(l)}(x_k)_{ij}}{\|F_t^{(l)}(x_k)_{ij}\|_{\ell_2}}, \quad \hat{F}_s^{(l)}(x_k)_{ij} = \frac{F_s^{(l)}(x_k)_{ij}}{\|F_s^{(l)}(x_k)_{ij}\|_{\ell_2}}. \quad (2)$$

通过训练网络输入图像, 该网络密集地提取局部图像区域的特征。将测试网络的集合进行训练, 以回归无异常数据的训练输出。在推理过程中, 测试网络将会在感受野覆盖异常区域的像素中产生回归误差, 用于预测其不确定性, 将用不同感受野生成的异常图进行组合, 用于多尺度的异常分割。其中损失函数为

$\ell^{(l)}(x_k)_{ij} \in (0, 1)$, 整个图像 x_k 的损耗是由每个位置的损失平均值给出的, 即

$$\ell^{(l)}(x_k) = \frac{1}{w^{(l)}h^{(l)}} \sum_{i=1}^{w^{(l)}} \sum_{j=1}^{h^{(l)}} \ell^{(l)}(x_k)_{ij}. \quad (3)$$

总损耗是不同金字塔等级损耗的加权平均值:

$$\ell(x_k) = \sum_{l=1}^L a^{(l)} \ell^{(l)}(x_k), \quad a^{(l)} \geq 0, \quad (4)$$

式中: $a^{(l)}$ 描述了第 l 个特征尺度对异常检测的影响。本文在所有的实验中简单地设定 $a^{(l)} = 1, l = 1, 2, \dots, L$ 。从训练集 X 中选定最小批次 b , 通过最小损失化[式(5)]来更新测试网络, ℓ_b 代表最小损失值, 在整个过程中只更新测试网络, 训练网络保持稳定。 ℓ_b 可表示为

$$\ell_b = \frac{1}{|b|} \sum_{k \in b} \ell^{(l)}(x_k). \quad (5)$$

2.4 异常图像测试阶段

测试阶段的目标是获得一个测试图像大小为

$w \times h$ 的异常图 Ω , 本文将测试图像样本集定义为 $Y = [y_1, y_2, \dots, y_n]$, 测试图像 $y_k \in \mathbb{R}^{h \times w \times c}$ 。分数 $\Omega_{ij} \in [0, 1]$ 表示位置 (i, j) 的像素与训练数据流形的偏差程度, 使用 $F_t^{(l)}(y)$ 和 $F_s^{(l)}(y)$ 分别表示训练和测试网络的第 l 个底层所产生的特征图, 据此可以计算出一个大小为 $w^{(l)} \times h^{(l)}$ 的异常图 $\Omega^{(l)}(y)$, 其中 $\Omega_{ij}^{(l)}(y)$ 是位置 (i, j) 的损失分数, 异常图 $\Omega^{(l)}(y)$ 通过双线性插值被上采样为 $w \times h$ 大小的图像, 最终得到的异常图像是 L 个大小相等的上采样异常图像元素之积:

$$\Omega(y) = \prod_{l=1}^L \text{Upsample}[\Omega^{(l)}(y)], \quad (6)$$

式中: Upsample 表示上采样操作。异常得分越高, 缺陷区域越大。因此, 本文选择 $\max[\Omega(y)]$ 作为测试

图像 y 的异常得分。

3 实验结果及分析

3.1 实验数据集

本文方法采用无监督学习方式, 训练集中仅包含无缺陷像素图像, 测试集包括正常图像以及具有不同类型缺陷的图像。图 4 给出了典型的 6 类像素的显微镜下图像, 分别为无缺陷、单类卫星点、多类卫星点、未打满 bank、过大墨滴溢出 bank、多缺陷等打印像素类型。通过数据增强算法扩充采集的初始样本的数量, 把所有图像尺寸调整为 $256 \text{ pixel} \times 256 \text{ pixel}$, 建立样本库。本文所采用初始喷墨打印 OLED 像素图像以及利用数据增广方法生成的图像示例如图 5 所示。




图 4 典型的 6 类样本。(a) 无缺陷; (b) 单类卫星点; (c) 多类卫星点; (d) 未打满 bank; (e) 过大墨滴溢出 bank; (f) 多缺陷
Fig. 4 Typical 6 types of samples. (a) Without defect; (b) single class satellite points; (c) multi class satellite points; (d) incomplete bank; (e) large droplet of ink overflows bank; (f) multiple defects




图 5 喷墨打印 OLED 像素图像数据增广示例。(a) 原图; (b) 随机锐度; (c) 翻转变换; (d) 随机对比度; (e) 随机裁剪; (f) 随机亮度
Fig. 5 Augmentation examples of inkjet printing OLED pixel image data. (a) Original image; (b) random sharpness; (c) flip transformation; (d) random contrast; (e) random cropping; (f) random brightness

从样本库中抽取任意足够无缺陷样例作为训练样本,针对不同类型缺陷随机抽取 20 张左右图像作为测试样例,对打印像素成膜完整性的缺陷检测主导特征

是集合特征且打印像素阵列性较强,因此这类检测对样本数量的要求不高。喷墨打印 OLED 像素数据集的样本分布如表 1 所示。

表 1 喷墨打印 OLED 像素数据集的样本数分布
Table 1 Sample distribution of OLED pixel data set for inkjet printing

Data set	Satellite point	Incomplete bank	Overflow	Multiple defects	Normal	Total
Train	0	0	0	0	860	860
Test	45	38	48	53	40	224
Total	45	38	48	53	900	1084

3.2 实验评估标准

本文使用 AUC 作为评估标准, AUC 被定义为 ROC(receiver operating characteristic) 曲线下的面积, 使用 AUC 作为评价指标是因为 ROC 曲线在很多时候并不能清晰地说明哪个分类器的效果更好, ROC 曲线的横坐标为假阳率 (R_{FP}), 纵坐标为真阳率 (R_{TP}), AUC 值越大代表分类器效果越好。 R_{FP} 和 R_{TP} 的计算公式如下:

$$\begin{cases} R_{FP} = \frac{F_P}{F_P + T_N} \\ R_{TP} = \frac{T_P}{T_P + F_N} \end{cases}, \quad (7)$$

式中: F_P 代表错误的正样本数; T_N 代表正确的负样本数; T_P 代表正确的正样本数; F_N 代表错误的负样本数。

本文分别在图像级和像素级对喷墨打印 OLED

打印像素图像进行了缺陷检测, 并且计算了两种标准下的 AUC 值。图像级异常检测的目的是判断图像中是否存在缺陷, 像素级异常检测的目的是提取缺陷位置信息以精确分割图像中的异常区域。

3.3 实验结果

表 2 给出了喷墨打印 OLED 像素图像每一类别缺陷检测的性能指标。通过对比可以发现: 本文方法对单类卫星点、未打满 bank 两类缺陷的检测效果最佳, 可以保证 95% 以上的分割准确率; 本文方法对过大墨滴溢出 bank 和多缺陷类型的检测效果次之, 分割准确率在 83% 以上; 本文方法对于多类卫星点缺陷类型的缺陷检出率为 100%, 但同时也会把打印不均匀的像素点识别为缺陷, 导致缺陷分割框偏大, 造成分割准确率稍有下降, 在像素点打印均匀的情况下, 该情况可以得到极大的改善。

表 2 喷墨打印 OLED 像素图像每一类别缺陷检测的性能指标
Table 2 Performance index of defect detection for each category of inkjet printed OLED pixel image

Defect type	Image level AUC / %	Pixel level AUC / %
Single class satellite points	100.0	96.5
Multi class satellite points	100.0	85.0
Incomplete bank	99.8	95.1
Large droplet of ink overflows bank	99.9	83.9
Multiple defects	99.3	83.5
Average	99.8	88.8

表 3 对比了本文方法与目前基于特征空间的无监督缺陷检测方法 SPADE^[20]、PaDiM^[21] 在喷墨打印 OLED 像素数据集的缺陷检测 AUC 值, 以单类卫星点为例, 本文对比显示了不同方法在喷墨打印 OLED 像素图像数据集上缺陷分割的效果, 如图 6 所示。图 6 (a) ~ (e) 表示使用方法 SPADE、PaDiM、ResNet18+FPN、ResNet18+Expanded FPN 对单类卫星点进行检测的原图、地面实况图、预测热图、预测二值图以及最后的缺陷分割结果。可以发现, 即使只有少量训练图像可用, 本文设计的模型仍然达到了令人满意的效果, 相比之下, SPADE 的性能严重下降, 这是由缺少定制的特征学习造成的, 本文模型可以在

少量数据中很好地捕捉到无缺陷图像的特征分布, 说明了本文方法对喷墨打印 OLED 像素缺陷检测的有效性。

图 7 (a) ~ (e) 分别为使用本文方法对喷墨打印 OLED 像素进行缺陷检测的原图、地面实况图、预测热图、预测二值图以及最后的缺陷分割结果, 本文方法主要进行基于像素成膜完整性的缺陷检测, 能够对喷墨打印 OLED 像素缺陷区域实现比较精确的识别检测。

4 结 论

本文提出了一种基于拓展型 FPN 的 OLED 像素

表 3 不同方法在喷墨打印 OLED 数据集上的缺陷检测效果对比

Table 3 Comparison of defect detection effects of different methods on inkjet printed OLED data sets

Algorithm	Image level AUC / %	Pixel level AUC / %
SPADEE	85.5	79.7
PaDiM	95.3	84.2
ResNet18+FPN	94.3	85.1
ResNet18+Expanded FPN	99.8	88.8




图 6 不同方法在喷墨打印 OLED 像素图像数据集上缺陷分割的效果。(a)原图;(b)地面实况图;(c)预测热图;(d)预测二值图;(e)缺陷分割结果

Fig. 6 Effect of different methods on defect segmentation in inkjet printing OLED pixel image data set. (a) Original images; (b) ground truths; (c) predicted heat maps; (d) predicted binary masks; (e) defect segmentation results

缺陷检测方法。针对喷墨打印 OLED 像素缺陷特点,在原始 FPN 的基础上进行拓展,有效获得不同层次等级的区域细节,以金字塔的方式整合来自高层的语义信息,从而丰富底层特征、增强细节对比度,以对 OLED 像素缺陷实现更加精确的检测。另外,结合 ResNet18,本文方法在 OLED 像素图像数据量有限的

条件下具有较强的泛化能力。结果表明,相比其他方法,本文方法表现出优越的性能,在喷墨打印 OLED 像素数据集上的缺陷检出率达到 99.8%,缺陷检测分割精度达到 88.8%,在这类小样本数据集上可以取得比较好的检测效果,基本满足 OLED 大尺寸量产工业需求。




图 7 所提方法在各个缺陷上的分割效果图。(a)原图;(b)地面实况图;(c)预测热图;(d)预测二值图;(e)缺陷分割结果
 Fig. 7 Segmentation effect of proposed method on each defect. (a) Original images; (b) ground truths; (c) predicted heat maps; (d) predicted binary masks; (e) defect segmentation results

参 考 文 献

[1] 于超, 陈琛, 吴丹, 等. 喷墨打印钙钛矿光电器件的研究进展 [J]. 液晶与显示, 2021, 36(1): 158-175.
 Yu C, Chen C, Wu D, et al. Research progress of inkjet printed perovskite optoelectronic devices[J]. Chinese Journal of Liquid Crystals and Displays, 2021, 36(1): 158-175.

[2] Lan L H, Zou J H, Jiang C B, et al. Inkjet printing for electroluminescent devices: emissive materials, film formation, and display prototypes[J]. Frontiers of Optoelectronics, 2017, 10 (4): 329-352.

[3] 李寒东. 喷墨印刷将推动 OLED 显示制造技术快速发展[J]. 网印工业, 2018(3): 24-25.
 Li H D. Ink jet printing will promote the rapid development of OLED display manufacturing technology[J]. Screen Printing Industry, 2018(3): 24-25.

[4] 上泉元, 罗伯特·巴查迟. 用于同时喷墨打印和缺陷检验的方法和装置: CN1903573[P]. 2007-01-31.
 Shang Q Y, Bachrach R. Methods and apparatus for concurrent inkjet printing and defect inspection: CN1903573[P]. 2007-01-31.

[5] 卢荣胜, 吴昂, 张腾达, 等. 自动光学(视觉)检测技术及其在缺陷检测中的应用综述[J]. 光学学报, 2018, 38(8): 0815002.
 Lu R S, Wu A, Zhang T D, et al. Review on automated optical (visual) inspection and its applications in defect detection[J]. Acta Optica Sinica, 2018, 38(8): 0815002.

[6] 汪志亮, 高健, 赵伟明. 面向 OLED 屏像素缺陷检测的新方法 [J]. 计算机工程与应用, 2012, 48(26): 177-180.
 Wang Z L, Gao J, Zhao W M. New method for OLED pixel defect detection[J]. Computer Engineering and Applications, 2012, 48(26): 177-180.

[7] 欧阳韬. 基于机器视觉的 OLED 屏混色缺陷检测算法[J]. 现代计算机(专业版), 2017(29): 56-60, 64.
 Ouyang T. Image detection algorithm for chromatic defect of OLED based on machine vision[J]. Modern Computer, 2017 (29): 56-60, 64.

[8] 简川霞, 王华明, 徐进军, 等. OLED 显示屏表面缺陷自动检测方法[J]. 包装工程, 2021, 42(13): 280-287.
 Jian C X, Wang H M, Xu J J, et al. Automatic surface defect detection for OLED display[J]. Packaging Engineering, 2021,

- 42(13): 280-287.
- [9] Kwak J, Lee K B, Jang J, et al. Automatic inspection of salt-and-pepper defects in OLED panels using image processing and control chart techniques[J]. *Journal of Intelligent Manufacturing*, 2019, 30(3): 1047-1055.
- [10] Sindagi V A, Srivastava S. Domain adaptation for automatic OLED panel defect detection using adaptive support vector data description[J]. *International Journal of Computer Vision*, 2017, 122(2): 193-211.
- [11] Lee J. 16-4: Invited paper: region-based machine learning for OLED Mura defects detection[J]. *SID Symposium Digest of Technical Papers*, 2021, 52(1): 200-203.
- [12] Bao W Y, Chao Z, Yang Z H, et al. P-13.14: two inspection methods of image quality & appearance based on edge crack of OLED display module[J]. *SID Symposium Digest of Technical Papers*, 2021, 52(S2): 1048-1049.
- [13] Singh R, Kumar G, Sultania G, et al. Deep learning based MURA defect detection[J]. *EAI Endorsed Transactions on Cloud Systems*, 2019, 5(15): 162217.
- [14] Song S B, Yang K C, Wang A N, et al. A Mura detection model based on unsupervised adversarial learning[J]. *IEEE Access*, 2021, 9: 49920-49928.
- [15] 宋智勇, 潘海鹏. 基于空间注意力多尺度特征融合的织物缺陷分类算法[J]. *激光与光电子学进展*, 2022, 59(10): 1010005.
Song Z Y, Pan H P. Fabric defect classification algorithm based on multi-scale feature fusion of spatial attention[J]. *Laser & Optoelectronics Progress*, 2022, 59(10): 1010005.
- [16] 田丰, 李莹, 王静. 基于多尺度小波变换融合的视网膜血管分割[J]. *光学学报*, 2021, 41(4): 0410001.
Tian F, Li Y, Wang J. Retinal blood vessel segmentation based on multi-scale wavelet transform fusion[J]. *Acta Optica Sinica*, 2021, 41(4): 0410001.
- [17] 刘峰, 郭猛, 王向军. 基于跨尺度融合的卷积神经网络小目标检测[J]. *激光与光电子学进展*, 2021, 58(6): 0610012.
Liu F, Guo M, Wang X J. Small target detection based on cross-scale fusion convolution neural network[J]. *Laser & Optoelectronics Progress*, 2021, 58(6): 0610012.
- [18] 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, June 26-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [19] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 936-944.
- [20] Cohen N, Hoshen Y. Sub-image anomaly detection with deep pyramid correspondences[EB/OL]. (2020-05-05) [2021-08-09]. <https://arxiv.org/abs/2005.02357>.
- [21] Defard T, Setkov A, Loesch A, et al. PaDiM: a patch distribution modeling framework for anomaly detection and localization[M]//del Bimbo A, Cucchiara R, Sclaroff S, et al. Pattern recognition. ICPR international workshops and challenges. Lecture notes in computer science. Cham: Springer, 2021, 12664: 475-489.

Detection Method for OLED Pixel Defects Based on Extended Feature Pyramid

Liu Lan¹, Ye Yun^{1,2*}, Guo Tailiang^{1,2}

¹College of Physics and Information Engineering, Fuzhou University, Fuzhou 350100, Fujian, China;

²Fujian Science & Technology Innovation Laboratory for Optoelectronic Information of China, Fuzhou 350100, Fujian, China

Abstract

Objective Preparing organic light-emitting diode (OLED) displays by inkjet printing technology is a research direction for next-generation display technologies. This technology is a material-saving deposition technology characterized by simple process, low cost, low power consumption, and capability for mass production, and it has thus been widely used in the electronics industry. The inkjet printing process imposes an extremely strict requirement on the accuracy of the process parameters, and printing defects are prone to occur when the parameters are outside the error ranges. In the preparation process, the printed OLED pixel image consists of repetitive and equally spaced horizontal and vertical lines, and this background texture varies with illumination conditions. The variation in texture, the low contrast of the defective pixels, and the changing size of the defective area pose a great challenge to the detection of printing defects. The possible printing defects are divided into two main categories: film-forming integrity defects in printed OLED pixels and film thickness uniformity defects in printed OLED pixels. Among them, film-forming integrity defects include the presence of satellite points, failure to cover the whole bank, overflow of overlarge ink droplets from the bank, and a mix of multiple types of defects. Automatic optical inspection (AOI) technology is widely used for the detection of OLED defects. Although most of the existing methods achieve favorable results in detecting the defects on the OLED panel surface, they tend to ignore the detailed features of defects in printed OLED pixels when they are applied to detect such defects. They are insufficient in the cases of limited printed pixel images and tiny pixel defects and consequently fail to deliver favorable results in pixel defect detection when the quality of printed OLED pixel images is reduced. To effectively improve the accuracy of the detection of OLED pixel defects and achieve the intelligent detection of inkjet-printed OLED pixel defects, this paper proposes an extended feature pyramid network (FPN) and applies it to the task of detecting OLED pixel defects.

Methods The features are enhanced by fusing the feature pyramids at different levels. A dedicated feature extraction module for small targets is added to enhance the sensitivity of the detection of OLED pixel defects. Then, an additional high-resolution pyramid layer is used to extract credible regional details, and the channel capacity is reduced by fusing the two pyramid layers at bottom to fully utilize the information from the underlying feature map. Finally, transfer learning is applied to limited samples to address the problem of low goodness of fit caused by insufficient sample data.

Results and Discussions Specifically, the microscopic images of six typical types of pixels are presented (Fig. 4). To prevent the problems of low detection accuracy, low goodness of fit, and poor robustness of the detection model resulting from insufficient samples of inkjet-printed OLED pixels, this paper extends the number of initial samples collected by a data augmentation algorithm (Fig. 5). The sample datasets are built (Table 1), and the defects in the inkjet-printed OLED pixel images with defects of different types are detected. According to the results, the method proposed in this paper performs best in detecting two types of defects, namely, single-class satellite points, and failures to cover the whole bank. It delivers the second-best results in detecting the overflow of overlarge ink droplets from the bank and the mix of multiple types of defects (Table 2). Subsequently, the paper compares the defect detection area under the curve (AUC) values of the proposed method and the current unsupervised defect detection methods based on feature space, i. e., semantic pyramid anomaly detection (SPADE) and patch distribution modeling (PaDiM), on the inkjet-printed OLED pixel image dataset. Then, taking the single-class satellite points as an example, this paper compares the effectiveness of different methods in defect segmentation on the inkjet-printed OLED pixel image dataset (Fig. 6). By contrast, the performance of SPADE algorithm severely degrades, and this is caused by the lack of customized feature learning. The model proposed in this paper can capture the feature distribution of defect-free images well in a small amount of data, indicating the effectiveness of the proposed method in detecting inkjet-printed OLED pixel defects.

Conclusions This paper proposes a detection method for OLED pixel defects based on an extended FPN. According to the features of inkjet-printed OLED pixel defects, the paper extends the original FPN, effectively obtains regional details at different levels of the hierarchy, and integrates semantic information from higher levels in a pyramidal manner to enrich the underlying features and enhance the contrast of details. More accurate detection of OLED pixel defects is thereby achieved. In addition, combined with ResNet18, the method proposed in this paper attains a robust generalization ability for a limited amount of OLED pixel image data. The results show that compared with other methods, the proposed method demonstrates superior performance, with a defect detection rate of 99.8% and a defect segmentation accuracy of 88.8% on the inkjet-printed OLED pixel dataset. Therefore, the proposed method can achieve favorable detection results on such small sample datasets and largely meets the industrial demand of OLED mass production in large sizes.

Key words measurement; organic light-emitting diode; inkjet printing; defect detection; feature pyramid; defect segmentation