

# 基于无监督网络的手机屏幕缺陷分割方法

代朝东<sup>1,2</sup>, 许国良<sup>2\*</sup>, 毛骄<sup>1,2</sup>, 顾桐<sup>1,2</sup>, 雒江涛<sup>2</sup>

<sup>1</sup>重庆邮电大学通信与信息工程学院, 重庆 400065;

<sup>2</sup>重庆邮电大学电子信息与网络工程研究院, 重庆 400065

**摘要** 针对工业上手机屏幕缺陷检测准确度不高, 分割精度低等问题, 提出一种基于无监督网络的方法, 实现手机屏幕的缺陷分割。首先, 通过无监督的卷积去噪自编码器构建多尺度特征的图像重构网络, 实现从缺陷图像中重构出多层背景纹理图像。然后, 将缺陷图像与多层背景重构图像分别进行减法运算, 消除背景纹理的影响。最后, 通过自适应阈值策略进行分割处理, 再将多层分割结果进行融合, 提升缺陷分割准确度。为提升重构性能, 在网络中结合一种改进的损失函数进行训练。在分割处理中, 根据残差图像的像素直方图是单峰的特点, 使用三角法进行自适应阈值分割, 提升分割精确度。经实验验证, 通过本文方法进行手机屏幕的缺陷分割, 分割精度达到 90.30%, 准确度和实时性满足工业要求, 并具有实用性。

**关键词** 机器视觉; 缺陷分割; 手机屏幕; 无监督网络; 图像重构网络; 阈值分割

中图分类号 TP391.41

文献标志码 A

doi: 10.3788/LOP202158.2015003

## Cell Phone Screen Defect Segmentation Based on Unsupervised Network

Dai Chaodong<sup>1,2</sup>, Xu Guoliang<sup>2\*</sup>, Mao Jiao<sup>1,2</sup>, Gu Tong<sup>1,2</sup>, Luo Jiangtao<sup>2</sup>

<sup>1</sup> College of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing, 400065, China;

<sup>2</sup> Institute of Electronic Information and Network Engineering, Chongqing University of Posts and Telecommunications, Chongqing, 400065, China

**Abstract** Based on an unsupervised network, a method for cell phone screen defect segmentation is proposed to solve the problem of low accuracy in cell phone screen defect detection. First, an image reconstruction network with multiscale features is constructed through an unsupervised convolutional denoising autoencoder, which reconstructs the multilayer background texture image from the defect image. Then, the defect and multilayer-reconstructed images are subtracted separately to eliminate the influence of the background texture. Finally, adaptive threshold strategy is used for segmentation and the segmentation results are fused to improve the accuracy of defect segmentation. To improve the reconstruction performance, an improved loss function is proposed to train the reconstruction network. Based on an image pixel histogram, the triangle method is used for global adaptive threshold segmentation to improve the segmentation accuracy. The experimental result shows that the proposed method can predict the cell phone screen defect area, reaching 90.30% accuracy. The accuracy and real time of the proposed method meet industrial requirements and it is practical.

**Key words** machine vision; defect segmentation; cell phone screen; unsupervised network; image reconstruction network; threshold segmentation

**OCIS codes** 150.1835; 100.3010; 100.2000

收稿日期: 2020-11-25; 修回日期: 2020-12-24; 录用日期: 2021-01-11

基金项目: 重庆市技术创新与应用示范(产业类重点研发)项目(cstc2018jszx-cyzdX0124)

通信作者: \*xugl@cqupt.edu.cn

## 1 引言

目前手机屏幕市场仍然大部分采用薄膜晶体管液晶显示器(TFT-LCD),TFT-LCD 手机屏幕技术科学含量高,但生产工艺水平受限,难以保证百分之百合格率,因此需要进行严格的质量检测。传统的人工检测成本高、检测效率低。为此,工业上开展了针对手机屏幕的自动化检测,通过工业相机采集手机屏幕图像,输入到控制处理系统进行缺陷检测。尤其近年来,深度学习在机器视觉的广泛应用,给缺陷检测打开了新的思路,将深度学习技术应用于手机屏幕缺陷检测极具研究价值<sup>[1]</sup>。

传统机器视觉方法中,研究者主要通过拟合纹理背景或抑制纹理背景,来消除对缺陷部分的影响。Lu 等<sup>[2]</sup>通过选取合适的奇异值进行全局图像的纹理背景重构,再通过抑制算法,实现背景纹理的有效去除。陈良敏<sup>[3]</sup>通过 Gabor 滤波器进行背景纹理抑制,在亮度均匀校正后通过改进的主动轮廓算法来进行缺陷分割。Liao 等<sup>[4]</sup>结合图像金字塔结构,将多层级的手机屏幕图像划分为多个不重叠像素块,对每个像素块采用局部自适应增强算法进行缺陷定位。

深度学习中的目标检测网络和语义分割网络广泛应用于缺陷检测后,国内外学者进行了相关研究。宋威<sup>[5]</sup>通过数据扩充的方法,建立训练数据集,使用 Faster-RCNN 目标检测网络对手机屏幕缺陷图像进行特征提取和缺陷检测。Yu 等<sup>[6]</sup>通过两阶段的全卷积网络,先进行粗略的缺陷区域提取,再对区域中的缺陷进行细化分割。Chen 等<sup>[7]</sup>采用三阶段方式进行缺陷检测,先通过 SSD (Single Shot MultiBox Detector) 网络定位大致位置,再通过 YOLO 网络进行细致定位,最后将检测框输入分类网络判别是否存在缺陷。Ronneberger 等<sup>[8]</sup>提出 U-Net 语义分割网络,通过多层的跳跃连接进行高低层的特征融合,保证语义信息不会丢失,得到较好的分割效果。Tabernik 等<sup>[9]</sup>提出两阶段设计,先通过分割网络对表面缺陷进行像素定位,再使用分割输出和分割网络的特征,进行二值图像分类。

另外,也有学者通过神经网络进行背景重构,以实现背景纹理的消除。张宏伟等<sup>[10]</sup>利用卷积去噪自编码器构建织物图像重构模型,再进行残差计算,最后使用数学形态学分割缺陷。Zhao 等<sup>[11]</sup>通过自编码器和生成式对抗(GAN)网络结构,对缺陷图像进行背景重构,使用局部二值模式(LBP)进行对比度增强来检测缺陷。Lv 等<sup>[12]</sup>通过结构相似度损失

函数进行纹理背景构建,再结合离散余弦变换进行缺陷分割。Yang 等<sup>[13]</sup>通过图像金字塔构建多层级的重构网络,再通过特征聚类进行缺陷分割。Mei 等<sup>[14]</sup>先使用韦伯定律进行光照归一化,再通过网络进行重构,计算残差后的均值和方差来确定阈值,实现缺陷分割。

通过以上研究,手机屏幕的缺陷检测方法还存在以下问题:1)基于传统机器视觉的缺陷检测算法,在针对特定情况进行算法设计时,参数设置无法自适应,导致算法不具有通用性。2)基于目标检测网络和语义分割网络的缺陷检测算法,训练的是有监督网络,需要大量的缺陷数据,并具有缺陷标注信息,而手机屏幕缺陷图像可获取的数据量少,自身存在小且不清晰的特点,导致人工标注成本高,数据集构建难度大。3)基于图像重构网络的缺陷检测算法,网络的重构效果很大程度上影响着分割结果,在分割处理中也未充分考虑残差图像的特点,处理中易出现过分割或欠分割,造成缺陷错检或漏检。

因此,针对 TFT-LCD 手机屏幕中,基于图像重构网络的缺陷检测算法存在的问题,本文提出一种基于无监督网络的缺陷分割方法,通过卷积去噪自编码器构建图像重构网络,再通过图像处理方法进行缺陷分割。本文的主要工作有:1)在网络构建中,结合一种改进的损失函数,提升网络重构性能,并采用多尺度特征结构,从不同特征层进行图像重构;2)在分割处理中,根据残差图像是单峰直方图的特点,通过三角法进行自适应阈值分割,提升缺陷分割精确度;3)将多层特征的分割结果进行融合,提升缺陷分割准确度。实验结果表明,通过本文方法能够高效准确地进行手机屏幕缺陷分割,具有实用性。

## 2 基本原理

TFT-LCD 手机屏幕是由薄膜晶体管组成,在图像上会呈现出规则的纹理背景,而这些纹理背景会对缺陷部分的检测造成影响,如图 1 所示。因此,此项工作的难点就是如何在具有纹理背景的图像中找出缺陷部分,并对缺陷部分进行像素级分割。由于手机屏幕这种特殊的材质,通过图像进行缺陷检测,会对纹理背景和亮度变化造成影响,而本文方法通过神经网络来进行背景纹理图像的重构,让网络学习图像的数据特征表示,使得重构前后的图像具有相似的纹理结构和亮度分布,可以避免图像亮度不均造成的影响,再根据图像的特点,选择合适的图像处理方法进行缺陷分割,具有高效和稳定的特点。




图 1 手机屏幕纹理背景。(a)无缺陷图像;(b)缺陷图像

Fig. 1 Cell phone screen texture background. (a) Defect-free image; (b) defect image

### 2.1 算法流程

本文提出的手机屏幕缺陷分割方法主要分为两部分,包括背景图像重构部分和缺陷分割处理部分。算法思想是:通过图像重构网络,从缺陷图像中重构出背景纹理图像,然后对缺陷图像进行背景纹理抑制,实现缺陷分割。算法整体框架如图 2 所示,具体步骤如下:

1) 缺陷图像  $I$  通过多尺度特征的图像重构网络,获得第  $n$  层多层特征的背景重构图像  $I_{rec\_n}$ ; 2) 缺陷图像  $I$  与多层特征的背景重构图像  $I_{rec\_n}$  进行减法运算; 3) 通过三角法进行自适应阈值分割; 4) 利用中值滤波器去除噪点,得到残差图像  $I_{res\_n}$ ; 5) 将多层特征的残差图像进行融合得到缺陷分割结果  $I_{result}$ 。

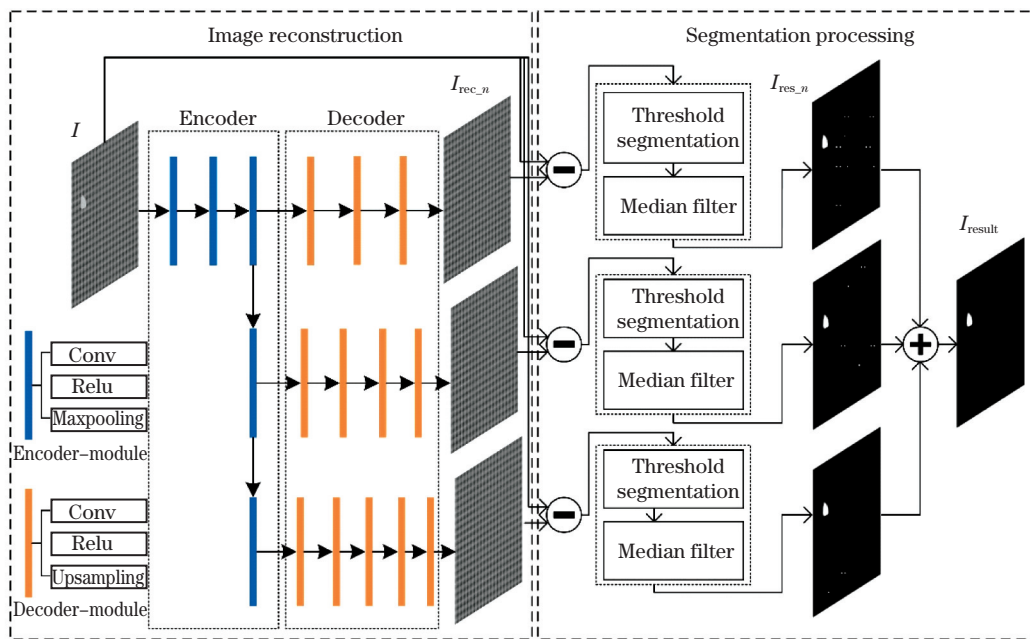


图 2 算法整体框架

Fig. 2 Algorithm overall framework

### 2.2 背景图像重构模块

去除图像纹理背景是进行缺陷分割的有效途径,本文通过图像重构网络来构建背景纹理图像,再通过减法运算消除缺陷图像中纹理背景对缺陷部分的影响<sup>[15]</sup>。通过无监督网络构建图像重构网络,具有以下特点: 1) 通过卷积去噪自编码器构建无监督的图像重构网络,仅用无缺陷图像进行网络训练,数据获取难度小且不用数据标注; 2) 网络采用多尺度特征结构,解码图像的多层特征信息,有助于提高缺陷分割准确度; 3) 结合一种改进的损失函数进行网

络训练,提升图像重构性能。

#### 2.2.1 卷积去噪自编码器

本文通过卷积去噪自编码器构建多尺度特征的图像重构网络。卷积去噪自编码器包含编码器和解码器两部分,网络从数据中提取特征,又从特征中恢复数据,输入的是图像,输出的也是图像,是一种学习输出等于输入的神经网络。通过在编码阶段前增加噪声模块,包括高斯噪声、椒盐噪声和掩模噪声,使输入图像  $I$  变为噪声图像  $I_{noise}$ ,编码器(EN)进行特征提取,解码器(DN)进行数据恢复,在损失函数的训练



指导下,网络的输出  $I_{rec_n}$  等于原始输入  $I$ ,从而使网

络具有去噪功能,去噪自编码器结构如图 3 所示。




图 3 去噪自编码器结构

Fig. 3 Denoising autoencoder structure

卷积去噪自编码器的编码器包含卷积层、池化层、激活函数层,用于实现对图像的特征提取和下采样。解码器包含卷积层、上采样层、激活函数层,用于实现特征恢复和上采样。通过卷积形式实现特征提取,可减少大量参数,一组卷积核适用于全图像,具有权值共享的特点。因此,通过卷积去噪自编码器进行特征提取和图像重构,可以有效实现重构功能,并且不会大幅度增加计算负担。

### 2.2.2 多尺度特征结构

多尺度特征是一种利用图像多层特征信息的方式,不同特征层具有不同的信息,高层特征的语义信息丰富,低层特征的几何细节信息丰富。通过对不同特征层进行背景重构,得到的重构图像也具有不同信息<sup>[16-17]</sup>。

图像重构网络的编码器不断进行卷积池化操作,在特征提取中,得到多层不同尺度的特征图  $I_{fea_n}$ ,再对不同尺度的特征图  $I_{fea_n}$  分别进行解码,得到重构图像。结合多尺度特征结构,对多层特征的重构图像进行分割处理,有助于提高缺陷分割的准确度。多尺度特征结构如图 1 中图像重构模块所示。

### 2.2.3 改进的损失函数

损失函数指导网络的训练方向,对输出结果起着决定性作用。在图像重构网络中,网络从缺陷图像中重构出背景纹理图像,理想情况下的背景重构图像,具有与缺陷图像中正常部分相似的亮度变化、对比度变化和纹理结构,并且能够消除缺陷图像上的缺陷部分。在图像重构网络中,常采用 L1 损失函数或 L2 损失函数,通过比较像素之间的差异进行网络训练,仅考虑图像的内容信息。但是没有考虑到人类视觉感知,以及图像自身的亮度变化、对比度变化和纹理结构<sup>[18]</sup>。结构相似性(SSIM)损失函数<sup>[19]</sup>比较的是图像的亮度、对比度和纹理结构,符合人类的视觉感知,生成的图像更有细节,但是缺乏具体的内容信息。因此,本文提出一种改进的损失

函数,综合考虑图像的内容信息以及图像亮度、对比度、纹理结构等信息。

SSIM 是衡量两幅图像相似度的指标,基于图像之间的亮度、对比度、纹理结构,均值  $\mu_x$  和  $\mu_y$  为亮度估计,标准差  $\sigma_x^2$  和  $\sigma_y^2$  为对比度估计,协方差  $\sigma_{xy}$  为结构相似性度量,表达式为

$$R_{SSIM}(x, y) = \frac{(2\mu_x\mu_y)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)}, \quad (1)$$

式中: $c_1$  和  $c_2$  为两个常数。SSIM 损失函数表达式为

$$L_{SSIM} = \frac{1}{N} \sum_0^N 1 - R_{SSIM}(x, y)。 \quad (2)$$

L1 损失函数基于图像进行逐像素比较取绝对值,有稳定的梯度,不会导致梯度爆炸问题,具有稳定的解,表达式为

$$L_{L1} = \frac{1}{N} \sum_0^N |x_i - y_i|, \quad (3)$$

式中: $N$  表示参数更新一次所输入图像的数量,即 Batch Size。最后整个图像重构网络的损失函数表达式为

$$L = \lambda_1 L_{SSIM} + \lambda_2 L_{L1}, \quad (4)$$

式中: $L$  表示图像重构网络的损失函数; $L_{SSIM}$  为结构相似性损失函数; $L_{L1}$  为 L1 损失函数。由于损失函数之间存在数量级差异,为防止数值差异过大,导致另一损失函数无法起作用,设置  $\lambda_1$  和  $\lambda_2$  为不同损失函数的比例系数,用于平衡损失函数。通过改进的损失函数进行网络训练,网络权重通过梯度反向传播进行权重更新。

$$w'_i = w_i - \alpha \frac{\partial L}{\partial w_i}, \quad (5)$$

式中: $w'_i$  为更新后权重; $\alpha$  为网络学习率。在不断训练中,输出与输入之间的损失越来越小,最终网络学习到去噪和重构功能,实现对缺陷图像的背景纹理重构。

### 2.3 缺陷分割处理模块

缺陷图像通过图像重构网络得到背景重构图像,再通过分割处理模块得到缺陷分割结果。分割处理模块具有以下特点:1) 缺陷图像与重构图像进行减法运算,抑制背景纹理对缺陷部分的影响;

2) 根据残差图像的像素直方图是单峰的特点,通过三角法进行自适应阈值分割;3) 通过中值滤波器去除图像上孤立的噪点;4) 多层特征的分割结果进行融合,进一步提高缺陷分割的准确度。分割处理过程如图 4 所示。

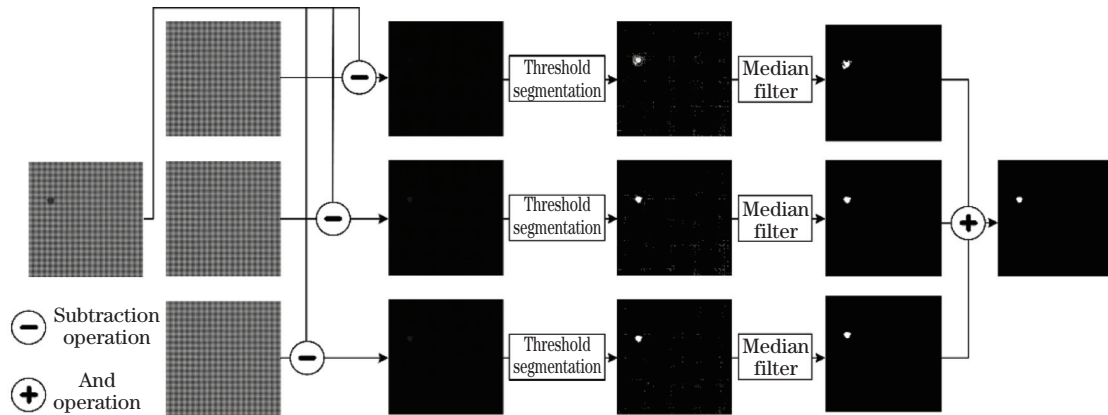


图 4 分割处理过程

Fig. 4 Segmentation process

#### 2.3.1 背景纹理抑制

缺陷图像通过多尺度特征的图像重构网络获得背景重构图像后,为实现对缺陷图像的背景纹理抑制,将缺陷图像  $I$  与重构图像  $I_{rec,n}$  进行空间域的减法运算,得到背景抑制后图像  $I_{res}$ ,运算表达式为

$$I_{res} = \text{abs}(I - I_{rec,n}) \quad (6)$$

通过减法运算后,消除背景纹理对缺陷部分的影响,图像像素值有差异的地方为缺陷可能存在的位置,残差图像像素分布如图 5 所示。

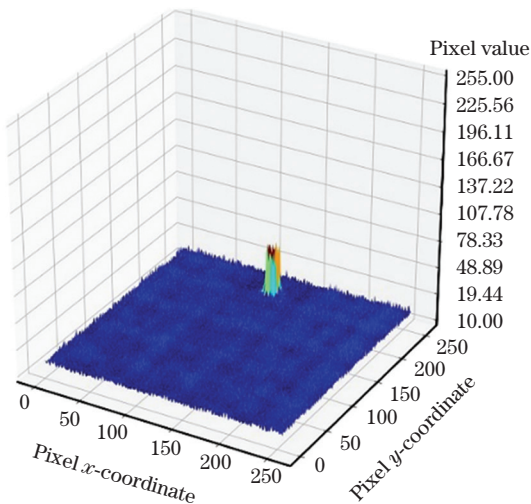


图 5 残差图像像素分布图

Fig. 5 Residual image pixel distribution

#### 2.3.2 缺陷阈值分割

阈值分割是一种基于区域的图像分割方法,实现简单、计算量小、性能稳定,适用于目标和背景具

有不同灰度范围的图像,通过选取合理的阈值,有助于提升分割精度。

阈值分割通常采用大津法,此方法适用于图像像素直方图为双峰图的情况,但手机屏幕缺陷是一些小缺陷,它的残差图像像素直方图为单峰图。因此,通过一种适用于单峰直方图的阈值分割法进行缺陷分割。

三角法<sup>[20]</sup>使用直方图数据,通过几何方法来确定阈值,通过对像素直方图最高峰到最低峰构造直线,计算直方图中的点到直线的最大垂直距离,最大距离所对应直方图点的位置为图像阈值,该方法适合单峰图像,并且具有全局自适应性,方法示意图如图 6 所示。通过三角法选取阈值后,将图像像素值与阈值进行比较,大于阈值的像素值置为 255,小于




图 6 三角法示意图

Fig. 6 Schematic of triangle method

阈值的像素值置为 0,对图像进行二值化处理。三角法的伪代码框图如图 7 所示。

#### Algorithm Triangle threshold segmentation

**Input:**  $I(i, j) = 0, 1, 2, \dots, 255$   
**Output:**  $I(i, j) = 0, 255$

1. Calculate pixel histogram  $H$
2. Initialize left bound  $l$  and right bound  $r$  from  $H$
3. Initialize peak value  $m$  and peak index  $n$  from  $H$
4. **If**  $(n - l < r - n)$  **then**
5.     compute flipped value  $l, r$  and  $n$
6.     initialize  $isflipped = True$
7. **end**
8. initialize threshold  $T$
9. initialize distance  $d = 0$
10. **for**  $i = l$  **to**  $r$  **do**
11.     compute  $temp = m \times i + (l - n) \times H[i]$
12.     **if**  $temp > d$  **then**
13.          $d = temp$
14.          $T = i$
15.     **end**
16. **end**
17. **If**  $isflipped = True$  **then**
18.      $T = 255 - T$
19. **end**
20. Calculate image binarization  $I$

图 7 三角法阈值分割的伪代码框图

Fig. 7 Pseudo-code graph of triangle threshold segmentation

#### 2.3.3 分割去噪与结果融合

通过图像去噪,可去除对分割结果有干扰的部分,再通过结果融合提高分割准确度。中值滤波是一种非线性滤波<sup>[21]</sup>,可以消除孤立噪点,有效抑制椒盐噪声,不损失图像轮廓以及边缘细节信息,其基本思想是把图像中某一点的值替换为该点邻域的中值,步骤为:1)滤波窗口在图像中滑动,将窗口中心与像素位置重合;2)读取窗口中的像素灰度值,将灰度值从小到大进行排序;3)将排序后的中值作为中心位置的像素灰度值。在图像中, $x_{i,j}$ 为图像  $I$  在  $(i,j)$  位置的像素灰度值,滤波窗口  $A$  为  $3 \times 3$  大小, $y_{i,j}$ 为滤波窗口中的中值,对图像进行中值滤波处理的表达式为

$$y_{i,j} = \text{median } A \{ \text{sort}(x_{i+r,j+s}) \}, \quad (7)$$

式中: $\text{sort}(x_{i+r,j+s})$ 为像素灰度值按从小到大排序; $r, s$ 表示中心像素点与其邻域距离( $r, s = -1, 0, 1$ )。因此,通过中值滤波来消除二值化后图像中残余噪点的干扰,提升缺陷分割精确度。

在多尺度特征图像重构网络中,从不同尺度的特征中进行图像重构,得到多张重构图像,分别进行分割处理后,得到残差结果  $I_{\text{rec}_n}$ 。将分割结果进行融合,采用图像间求与运算的方式,得到最后的缺陷分割图  $I_{\text{result}}$ ,提升缺陷分割准确度,运算定义式为

$$I_{\text{result}} = \bigwedge_1^n I_{\text{res}_n}, \quad (8)$$

式中: $I_{\text{rec}_n}$ 表示第  $n$  层特征的重构图像的分割结果; $\wedge$ 表示与运算。

## 3 实验分析与讨论

本文实验环境配置:CPU 为英特尔 i7-9750H,内存为 16 G, GPU 型号为 GTX1660Ti,显存为 6 G,网络模型均在 Keras 框架下进行,通过 Python 语言进行编程,以及 OpenCV 开源计算机视觉库进行辅助处理。

### 3.1 数据集的构建

通过工业相机采集手机屏幕图像,图像分辨率约为  $2640 \times 1580$ ,由于神经网络无法输入原图进行处理,因此对原图进行切割和筛选,选取了 105 张缺陷图像,包括点、线、块等缺陷类型,通过对图像进行数据增强,以及无缺陷图像上人工模拟出不同对比度和不同形状的缺陷进行数据扩充。最终,得到缺陷图像 2556 张,无缺陷图像 3000 张,均为  $256 \times 256$  大小,数据集构成如表 1 所示。

表 1 数据集组成

Composition	Number
Point defect image	831
Line defect image	757
Block defect image	968
Defect-free image	3000

### 3.2 算法评价指标

通过评价指标对重构网络性能和缺陷分割效果进行验证。重构性能的评价指标包括峰值信噪比 (PSNR) 和 SSIM。PSNR 通过计算最大像素值以及图像之间的均方误差得到,定义为

$$R_{\text{PSNR}} = 10 \times \lg \left[ \frac{E_{\text{MAX-I}}^2}{E_{\text{MSE}}} \right]. \quad (9)$$

对于分割结果的评价指标,通过精准率、召回率、F1 分数和  $K$  类的平均交并比 (mIoU) 进行评价,定义为

$$R_{\text{Precision}} = \frac{R_{\text{TP}}}{R_{\text{TP}} + R_{\text{FP}}}, \quad (10)$$

$$R_{\text{Recall}} = \frac{R_{\text{TP}}}{R_{\text{TP}} + R_{\text{FN}}}, \quad (11)$$

$$R_{\text{F1-score}} = \frac{2 \times R_{\text{Precision}} \times R_{\text{Recall}}}{R_{\text{Precision}} + R_{\text{Recall}}}, \quad (12)$$

$$R_{\text{mIoU}} = \frac{1}{K+1} \sum_{i=0}^k \frac{R_{\text{TP}}}{R_{\text{TP}} + R_{\text{FP}} + R_{\text{FN}}}, \quad (13)$$

式中: $R_{\text{TP}}$ 表示正类预测为正类; $R_{\text{TN}}$ 表示负类预测



为负类; $R_{FP}$  表示负类预测为正类,也叫误检; $R_{FN}$  表示正类预测为负类,也叫漏检。

### 3.3 实验结果与分析

在验证重构性能的实验中,通过对不同比例系数的损失函数进行网络训练,进行重构性能的对比如表 2 所示。

表 2 不同损失函数下的重构性能

Table 2 Reconstruction performance of different loss functions

Loss function	PSNR /dB	SSIM	Loss function	PSNR /dB	SSIM
L1	42.1259	0.9724	SSIM+100L1	41.8797	0.9738
L2	42.5081	0.9760	SSIM+L2	42.2828	0.9795
SSIM	41.7716	0.9785	10SSIM+L2	40.1075	0.9785
SSIM+L1	43.6948	0.9833	100SSIM+L2	40.9973	0.9799
10SSIM+L1	40.6120	0.9753	SSIM+10L2	41.1022	0.9739
100SSIM+L1	41.4517	0.9793	SSIM+100L2	39.7973	0.9681
SSIM+10L1	41.4988	0.9746			

经实验验证,SSIM 损失函数和 L1 损失函数组合,比例系数均为 1 的时候效果最好,相比单一的损失函数,在一定程度上提高了网络的重构性能。L1 损失函数指导网络学习图像像素之间的内容信息,SSIM 损失函数指导网络学习整个图像的细节纹理信息,将两个损失函数进行组合训练,重构的背景图像在内容和细节纹理上都有了提高。

在网络构建中,网络层数的选择十分重要,网络层数较多会导致低层网络无法进行有效学习,网络层数较少会导致重构过程进行不完全,因此通过设置不同网络层数进行重构性能的比较,其中 3 层表示在网络的编码器部分为 3 层网络,在解码器部分也会设置相同层数的解码网络,结果如表 3 所示,通过实验对比最终选取了 5 层作为编码网络层数。另外,通过对网络编码部分进行多尺度的解码,得到多张背景纹理重构图像,再分别进行缺陷分割处理,可以有效降低重构性能的偶然性,相比在单尺度下的

把 SSIM 损失函数与 L1 损失函数和 L2 损失函数进行组合,分别训练单尺度特征的图像重构网络,再用模拟的缺陷图像来验证网络的重构性能,使用 PSNR 指标和 SSIM 指标来衡量性能好坏,实验结果如表 2 所示。

缺陷分割处理,进行多尺度分割结果融合后的缺陷分割精度提升了 0.3%。

表 3 不同网络层数下的重构性能

Table 3 Reconstruction performance of different network layers

Number of layers	PSNR /dB	SSIM
3-layer	37.3769	0.9641
4-layer	41.9443	0.9754
5-layer	43.3754	0.9808
6-layer	41.9229	0.9742
7-layer	39.1676	0.9615

图像重构网络的重构结果和分割处理的结果如图 8 所示,从上到下依次为缺陷图像、背景重构图像、分割结果、结果融合图像,从左往右分别为第一、二、三层特征尺度下的结果。从图中可以看出,网络能够较好地重构出背景纹理图像,在阈值分割后能够准确分割出缺陷部分,在结果融合后进一步提升缺陷分割准确度。




图 8 背景重构与缺陷分割结果

Fig. 8 Background reconstruction and defect segmentation results

通过缺陷数据集验证本文方法的实际效果,用评价指标进行测定,在进行完整的本文缺陷分割方法后,精准率达到 97.20%,召回率达到 92.47%,F1 分数达到 94.46%,分割精度达到 90.30%,每张缺陷图像的平均处理时间为 37.20 ms,满足工业要求,具有实用性。

将本文方法与传统方法 SVD<sup>[1]</sup>、有监督网络 U-Net<sup>[8]</sup>和同样是采用无监督方法的 MSCDAE<sup>[13]</sup>进行实验对比,SVD 方法通过奇异值分解从缺陷图像中进行背景纹理图像的重构,通过实验选取合适范围的主奇异值重构背景图像。U-Net 网络融合了

低层的图像信息和高层的特征信息,对于缺陷这类信息简单、结构固定的小目标,使得在特征提取中不会丢失过多相关信息,分割图也会保留更多的细节信息。实验通过数据增强构建缺陷数据集,再通过迁移学习的方法对网络进行训练和缺陷分割。MSCDAE 方法通过对缺陷图像构建图像金字塔结构,组成不同尺度的重构网络,在差值运算后通过统计分析图像灰度信息来选取阈值,分割出缺陷部分。三组实验均采用本文所制作的手机屏幕缺陷数据集,最终,在同一数据集以及同一设备下进行实验,缺陷分割结果对比如图 9 所示,评价指标对比如表 4 所示。




图 9 缺陷分割结果对比。(a)缺陷图像;(b)真值;(c)SVD;(d)U-Net;(e)MSCDAE;(f)本文算法

Fig. 9 Comparison of defect segmentation results. (a) Defect images; (b) ground truth; (c) SVD; (d) U-Net; (e) MSCDAE; (f) proposed method

表 4 实验指标对比

Table 4 Comparison of experimental index

Algorithm	Precision	Recall	F1-score	mIoU / %
SVD <sup>[1]</sup>	0.9507	0.8600	0.8959	84.15
U-Net <sup>[8]</sup>	0.9538	0.8017	0.8464	80.16
MSCDAE <sup>[13]</sup>	0.9517	0.9250	0.9333	89.10
Proposed method	0.9720	0.9247	0.9446	90.30

通过实验分析,文献[1]算法通过选取奇异值进

行背景纹理图像的重构,在实验中选择的主奇异值不具有自适应性,无法处理多种情况,在不同亮度下的重构效果各异,导致缺陷错检的情况较多。文献[8]算法由于缺陷图像中存在部分的缺陷对比度不高,网络模型难以分辨是背景还是缺陷,造成部分缺陷丢失,导致缺陷漏检。文献[13]算法的检测效果较好,但在网络构建中损失函数只考虑了图像间的内容信息,导致重构性能不高;在缺陷分割中,阈值选



取是对图像划分小块进行统计分析得出的,复杂度较高。本文方法进行的缺陷分割,在缺陷预测准确度和分割精确度上效果较好,算法复杂度较小,实时性上满足工业要求,具有工业实用性。

## 4 结 论

本文针对 TFT-LCD 手机屏幕缺陷检测,通过将深度网络与传统图像处理相结合,在实际应用中取得较好的分割效果。在无监督网络中采用改进的损失函数,使网络学习到图像的内容信息和细节纹理信息,提升网络的重构性能;通过三角法进行缺陷分割,有效提取缺陷部分,并结合多尺度特征的网络结构,对多层特征的分割结果进行融合,进一步提升缺陷分割的准确度。通过实验进行验证,结果表明,本文方法的重构性能相比单一的损失函数有了一定提升,不仅在分割效果上优于其他算法,在算法复杂度上也优于其他算法,可满足检测的实时性。

通过对手机屏幕进行缺陷检测,可以迅速把控产品质量问题,有效反馈产品生产部门,指导产品技术改进。本文方法除了可以应用于手机屏幕缺陷检测外,也同样适用于规则纹理背景或背景复杂度较低的其他工业表面缺陷检测。对于背景较复杂图像的缺陷检测,可研究利用生成对抗网络来进行这一挑战。

## 参 考 文 献

- [1] Liu W, Shao H L, He Y J, et al. Parameter adaptive LCD screen defect detection framework [J]. Journal of Harbin University of Science and Technology, 2020, 25(5): 75-82.  
刘望, 邵慧丽, 何勇军, 等. 参数自适应的液晶屏幕缺陷检测框架 [J]. 哈尔滨理工大学学报, 2020, 25(5): 75-82.
- [2] Lu C J, Tsai D M. Automatic defect inspection for LCDs using singular value decomposition [J]. The International Journal of Advanced Manufacturing Technology, 2005, 25(1/2): 53-61.
- [3] Chen L M. Detection and classification of Mura defect for TFT-LCD based on computer vision [D]. Shanghai: Shanghai Jiao Tong University, 2017.  
陈良敏. 基于机器视觉的 Mura 缺陷检测和分类方法研究 [D]. 上海: 上海交通大学, 2017.
- [4] Liao M, Liu Y Z, Ou Y J L, et al. Automatic detection of Mura defect in TFT-LCD mobile screen based on adaptive local enhancement [J]. Chinese Journal of Liquid Crystals and Displays, 2018, 33: 475-482.
- [5] Song W. Smart phone screen defect detection based on deep convolutional neural network [D]. Chengdu: University of Electronic Science and Technology of China, 2019.  
宋威. 基于深度卷积神经网络的手机屏幕缺陷检测 [D]. 成都: 电子科技大学, 2019.
- [6] Yu Z Y, Wu X J, Gu X D. Fully convolutional networks for surface defect inspection in industrial environment [M] // Liu M, Chen H Y, Vincze M. Computer vision systems. Lecture notes in computer science. Cham: Springer, 2017, 10528: 417-426.
- [7] 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.
- [8] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation [M] // Navab N, Hornegger J, Wells W M, et al. Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science. Cham: Springer, 2015, 9351: 234-241.
- [9] Tabernik D, Šela S, Skvarč J, et al. Segmentation-based deep-learning approach for surface-defect detection [J]. Journal of Intelligent Manufacturing, 2020, 31(3): 759-776.
- [10] Zhang H W, Tang W B, Li P F, et al. Defect detection and location of yarn-dyed shirt piece based on denoising convolutional autoencoder [J]. Basic Sciences Journal of Textile Universities, 2019, 32(2): 119-125, 132.  
张宏伟, 汤文博, 李鹏飞, 等. 基于去噪卷积自编码器的色织衬衫裁片缺陷检测 [J]. 纺织高校基础科学学报, 2019, 32(2): 119-125, 132.
- [11] Zhao Z X, Li B, Dong R, et al. A surface defect detection method based on positive samples [M] // Geng X, Kang B H. PRICAI 2018: trends in artificial intelligence. Lecture notes in computer science. Cham: Springer, 2018, 11013: 473-481.
- [12] Lv C, Zhang Z T, Shen F, et al. A fast surface defect detection method based on background reconstruction [J]. International Journal of Precision Engineering and Manufacturing, 2020, 21(3): 363-375.
- [13] Yang H, Chen Y F, Song K Y, et al. Multiscale feature-clustering-based fully convolutional autoencoder for fast accurate visual inspection of texture surface defects [J]. IEEE Transactions on Automation Science and Engineering, 2019, 16(3): 1450-1467.

- [14] Mei S, Yang H, Yin Z P. An unsupervised-learning-based approach for automated defect inspection on textured surfaces [J]. IEEE Transactions on Instrumentation and Measurement, 2018, 67(6): 1266-1277.
- [15] Liu W Q, Liu Z G, Wang H, et al. An automated defect detection approach for catenary rod-insulator textured surfaces using unsupervised learning [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(10): 8411-8423.
- [16] Yuan K P, Xi Z H. Image super resolution based on depth jumping cascade[J]. Acta Optica Sinica, 2019, 39(7): 0715003.  
袁昆鹏, 席志红. 基于深度跳跃级联的图像超分辨率重建[J]. 光学学报, 2019, 39(7): 0715003.
- [17] Liu M J, Cao Y Z, Zhu S Y, et al. Feature fusion video target tracking method based on convolutional neural network [J]. Laser & Optoelectronics Progress, 2020, 57(4): 041502.  
刘美菊, 曹永战, 朱树云, 等. 基于卷积神经网络的特征融合视频目标跟踪方法[J]. 激光与光电子学进展, 2020, 57(4): 041502.
- [18] Jiang Z T, He Y T. Infrared and visible image fusion method based on convolutional auto-encoder and residual block [J]. Acta Optica Sinica, 2019, 39(10): 1015001.  
江泽涛, 何玉婷. 基于卷积自编码器和残差块的红外与可见光图像融合方法[J]. 光学学报, 2019, 39(10): 1015001.
- [19] Bergmann P, Löwe S, Fauser M, et al. Improving unsupervised defect segmentation by applying structural similarity to autoencoders[C]//Proceedings of the 14th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications, February 25-27, 2019. Prague, Czech Republic. Setúbal: Science and Technology Publications, 2019: 372-380.
- [20] Zack G W, Rogers W E, Latt S A. Automatic measurement of sister chromatid exchange frequency [J]. The Journal of Histochemistry and Cytochemistry, 1977, 25(7): 741-753.
- [21] Zhao G C, Zhang L, Wu F B. Application of improved median filtering algorithm to image denoising[J]. Journal of Applied Optics, 2011, 32(4): 678-682.  
赵高长, 张磊, 武风波. 改进的中值滤波算法在图像去噪中的应用[J]. 应用光学, 2011, 32(4): 678-682.