

# 基于卷积去噪自编码器的芯片表面弱缺陷检测方法

罗月童 卞景帅 张蒙 饶永明 闫峰

合肥工业大学计算机与信息学院 合肥 230601



**摘要** 芯片表面缺陷会影响芯片的外观和性能,因此表面缺陷检测是芯片生产过程中的重要环节。具有缺陷与背景对比度低、缺陷较小等特点的弱缺陷给传统检测方法带来了挑战。因为近年来深度学习在机器视觉领域展现出了强大的能力,所以文中采用基于深度学习的方法来研究芯片表面弱缺陷的检测问题。该方法将芯片表面缺陷看作噪音,首先应用卷积去噪自编码器(Convolutional Denoising Auto-encoders,CDAE)重构无缺陷图像,然后用重构的无缺陷图像减去输入图像,获得包含缺陷信息的残差图。因为残差图中已经消除了背景的影响,所以最后可以基于残差图较容易地进行缺陷检测。由于基于CDAE重构芯片背景的无缺陷图像时存在随机噪音,导致弱缺陷可能会湮没在重构噪音中,为此,文中提出了重叠分块策略抑制重构噪音,以便更好地检测弱缺陷。因为CDAE是无监督学习网络,所以训练时无需进行大量的人工数据标注,这进一步增强了该方法的可应用性。通过对真实芯片表面数据进行测试,验证了所提方法在芯片表面检测上的有效性。

**关键词:** 芯片表面缺陷;缺陷检测;深度学习;无监督学习;卷积去噪自编码器

**中图分类号** TP391

## Detection Method of Chip Surface Weak Defect Based on Convolution Denoising Auto-encoders

LUO Yue-tong, BIAN Jing-shuai, ZHANG Meng, RAO Yong-ming and YAN Feng

School of Computer Science and Information Engineering, Hefei University of Technology, Hefei 230601, China

**Abstract** Chip surface defects can affect the appearance and performance of the chip. Therefore, surface defect detection is an important part of the chip production process. The automatic detection method based on machine vision attracts much attention because of its advantages of low cost and high efficiency. Weak defects such as low contrast between defects and background and small defects, bring challenges to traditional detection methods. Because deep learning has shown strong capabilities in the fields of machine vision in recent years, this paper studied the detection of weak defects on the chip surface by using the method based on deep learning. Chip surface defects were regarded as noise in this method. Firstly, convolutional denoising auto-encoders (CDAE) is applied to reconstruct the image without defect. Then, the reconstructed image without defect is used to subtract the input image, thus obtaining the residual image with defect information. Because the influence of background has been eliminated from the residual diagram, it is easier to detect defects based on the residual diagram. Because of the random noise in the process of reconstructing defect-free image from chip background image based on CDAE, the weak defect may be lost in the reconstructed noise. Therefore, this paper proposed an overlapping block strategy to suppress the reconstructed noise, so as to better detect the weak defect. Because CDAE is an unsupervised learning network, there is no need to perform a large amount of manual data annotation during training, which further enhances the applicability of the method. By using the real chip surface data provided by the paper partner, the effectiveness of the proposed method in chip surface detection is verified.

**Keywords** Chip surface defects, Defect detection, Deep learning, Unsupervised learning, Convolution denoising auto-encoders

芯片是半导体元件产品的统称,已经深入计算、交流、制造和交通等领域,成为现代社会不可或缺的一部分<sup>[1]</sup>。在生

到稿日期:2019-01-17 返修日期:2019-05-08 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国家重点研发计划(2017YFB1402200);安徽省科技强警计划项目(1604d0802009);浙江大学 CAD&CG 国家重点实验室开放课题(A1814);中央高校基本科研业务费专项资金(JZ2017HGBH0915);安徽省高等学校省级质量工程项目(2017jyxm0045)

This work was supported by the National Key Research and Development Plan of China (2017YFB1402200), Strengthen Police with Science and Technology Project of Anhui, China (1604d0802009), State Key Laboratory of CAD&CG, Zhejiang University (A1814), Fundamental Research Funds for the Central Universities of Ministry of Education of China (JZ2017HGBH0915) and Provincial Quality Engineering Project of the Higher Education Institutions of Anhui Province, China (2017jyxm0045).

通信作者:罗月童(ytluo@hfut.edu.cn)

产过程中,芯片表面可能出现图 1 所示的擦痕、划痕、熔化、裂纹等缺陷<sup>[1]</sup>,这些缺陷会影响芯片的外观和性能,因此需要将它们检测出来并加以处理。基于机器视觉的检测方法因为具有成本低、效率高等优点而被广泛应用于芯片生产的多个环节,如标识检测、管脚检测、晶圆检测和封装检测等<sup>[1]</sup>。芯片表面缺陷检测属于表面检测研究范畴。虽然表面检测存在通用的方法和理论,但因为不同应用领域的表面检测问题差别太大,所以大量针对具体的应用领域的研究发展出了各具特色的方法,如织物表面检测<sup>[2]</sup>、木材表面检测<sup>[3]</sup>、钢表面检测<sup>[4]</sup>等。随着表面检测技术的发展,芯片表面检测也受到关注。Chiou 等<sup>[5]</sup>首先利用彩色图像分割技术对 BGA(球栅阵列)型封装芯片的表面污点、划痕、焊锡掩模和针孔等缺陷进行特征提取与分析,然后利用反向传播神经网络对检测的缺陷进行分类,通过实验证明了该方法能够有效地检测电镀区域缺陷。Dong 等<sup>[6]</sup>提出了一种基于 Blob 分析的芯片表面缺陷检测方法,首先对芯片表面图像进行二值化,然后利用差影法去除字符干扰,最后对差影图像进行 Blob 缺陷提取。Su 等<sup>[7]</sup>提出了一种基于时域和频域特征的芯片表面缺陷检测方法,首先提取 11 个时域特征和 24 个频域特征共 35 个特征用于特征分析,然后引入遗传算法进行特征选择,最后采用反向传播神经网络进行缺陷分类与识别,通过实验证明了该方法能够有效地检测芯片表面的焊点缺陷。Feng 等<sup>[8]</sup>提出了一种基于序贯相似性与光源自动调节的芯片表面缺陷检测方法,首先基于序贯相似性检测匹配定位并提取出缺陷高发区域,然后利用光源自动调节机制消除光照对图像质量的影响,最后统计缺陷区域二值化图特征,完成芯片封装金属丝违规露出之类的破损缺陷检测。虽然上述方法都能够有效地检测出芯片表面的缺陷,但是它们处理的芯片表面缺陷与背景区域对比明显,缺陷特征能够被有效提取。由于芯片表面存在缺陷与背景对比度低、缺陷较小等特点的弱缺陷,缺陷目标、背景、噪声等信息包含在一个较窄的灰度范围内难以被区分,因此这给芯片表面缺陷自动检测方法带来了很大的挑战。




图 1 芯片表面缺陷类别

Fig. 1 Chip surface defect category

深度网络通过多层网络能够逼近复杂函数,能够从大量样本本集中学习数据的本质特征<sup>[9-10]</sup>。自 Hinton 等<sup>[11]</sup>于 2006 年提出深度学习的概念以来,其在计算机视觉、语音识别、自然语言处理等领域都取得了较好的效果。随着深度学习技术的发展,表面缺陷检测领域也积极探索了基于深度学习的表面检测方法。文献<sup>[12]</sup>使用深度残差神经网络检测基础设施(如管道、桥梁等)的缺陷(如裂缝、漏水等),在测试集上获得

了 87.5% 的准确率;文献<sup>[13]</sup>提出了一种基于卷积神经网络(CNN)的神经网络结构 CrackNet,该网络结构用于沥青路面裂缝检测,其检测精确度能够达到像素级别,在测试集中检测准确率达到 90.13%;Ren 等<sup>[14]</sup>提出了一种结合迁移学习的卷积神经网络(CNN)图像分类框架,然后利用已训练的分类器对输入的图像进行像素级别预测,这在木材表面缺陷中取得了较好的检测效果。尽管这些方法在表面检测上都很有效,但是它们都有一个共同问题,即都是基于有监督学习的,模型训练需要大量人工标记数据。但是在工业生产中,某些缺陷类型是不可预知的,因此难以对其进行人工标记,且人工标记工作量大,这也给实际基于有监督学习的方法的应用带来了很大困难。因为无监督学习方法无需数据标注,所以基于无监督学习的表面检测在近年逐渐受到关注。文献<sup>[15]</sup>提出了一种基于深度置信网络的太阳能电池片缺陷检测方法,该方法首先通过学习大量缺陷样本,得到训练样本到无缺陷模板之间的映射关系,然后对比重构图像与缺陷图像,实现样本的缺陷检测;Li 等<sup>[16]</sup>提出了一种基于 Fisher 准则的堆叠去噪自编码器网络模型,该模型用于可变形的图案化织物缺陷检测,通过对有缺陷和无缺陷的样本进行训练,可以有效地检测织物的表面缺陷;文献<sup>[17]</sup>提出了一种利用不同高斯金字塔等级的卷积去噪自编码器网络重构图像,使用重构残差图进行缺陷检测,通过实验验证了该方法在均匀和非规则纹理表面检测时具有一定的有效性。

综上所述,深度学习在表面检测中得到了广泛的应用,且基于无监督学习的检测方法逐渐受到重视,但目前尚未发现针对芯片表面弱缺陷检测的文献。因为芯片表面缺陷类型多变,缺陷样本数据难以收集,所以本文提出基于无监督学习的芯片表面弱缺陷检测方法。与文献<sup>[17]</sup>类似,本文方法将缺陷视为噪音,通过对比原始图像和基于去噪网络重构的图像来获取缺陷区域,进而实现缺陷区域的检测。与文献<sup>[17]</sup>不同,本文所处理的图像表面没有如织物一样的纹理特征,这给去噪重建带来了挑战;另外,某些芯片表面的缺陷非常微弱,这也给缺陷检测带来了挑战。本文使用合作单位提供的实际生产线数据进行测试,取得了较好的效果,得到了相关应用单位的认同。

## 1 方法概况

因为正常芯片的表面图像比较一致,而缺陷区域通常只占据表面很小的一部分,所以本文将缺陷看作表面图像的“噪音”,进而提出基于去噪神经网络的缺陷检测方法,整个检测流程如图 2 所示。

1) 基于 CDAE 的无缺陷图像重构: CDAE 网络能够充分发挥卷积神经网络在图像处理和无监督学习中的优势,能够有效地重构有损的输入数据,与普通自编码器相比其更具有鲁棒性;同时它也有利于避免收集大量缺陷数据和人工标记缺陷数据,这进一步增强了该方法的可用性。

2) 基于重叠分块的残差图生成: 因为在基于 CDAE 进行

芯片背景图像重构无缺陷图像时存在随机噪声,导致弱缺陷可能会湮没在重构噪声中,所以本文提出重叠分块策略来抑制重构噪声,该策略增强了缺陷区域与非缺陷区域的对比,使得基于残差图的缺陷检测更加简单。

3)基于残差图的缺陷检测:重叠分块的残差图生成策略提高了缺陷区域与非缺陷区域的对比度,使生成的残差图分割阈值比原始图像更容易确定,从而更容易分割缺陷。因此本文使用了自动阈值分割方法。

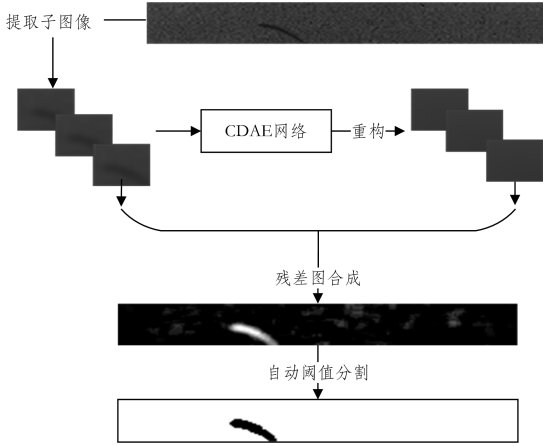


图2 基于CDAE的缺陷检测流程

Fig. 2 Defect detection process based on CDAE

## 2 基于CDAE的无缺陷图像重构

因为去噪网络可以去除图像中的噪声,使其恢复到正常图像,所以本文利用去噪网络重构无缺陷芯片表面图像。自Vincent等<sup>[18]</sup>提出去噪自编码器以来,目前已有卷积去噪自编码器(CDAE)<sup>[17]</sup>、堆叠式去噪自编码器(SDA)<sup>[19]</sup>等常用去噪网络。基于以下两点考虑,本文选择了CDAE网络。

1)CDAE网络由去噪自编码器发展而来。去噪自编码器属于无监督的学习方式,输入数据使用无标签的数据,可以避免人工标记训练数据。在芯片工业生产中,芯片表面缺陷类型多变,采用无监督的学习方式无需标记缺陷样本数据。正常芯片的表面数据比缺陷数据更容易收集,无监督学习的网络模型训练数据集更加容易构建。

2)CDAE结合卷积神经网络的卷积和池化操作,在实现特征提取的同时保留了二维图像的结构信息。在芯片表面检测中,采用CDAE网络能够有效提取到正常区域的图像特征。在网络模型训练上,SDA需要逐层训练,而CDAE的训练相对简单,无需逐层训练。

### 2.1 CDAE简介

在深度学习中,自编码器(Auto Encoder, AE)是一种非常有效的无监督学习模型,该模型可以看作由一个编码函数和一个生成重构的解码器两部分组成。编码函数和解码器分别如式(1)、式(2)所示:

$$z = f_{\theta}(x) \quad (1)$$

$$y = g_{\theta'}(z) \quad (2)$$

图3给出了AE的传统结构,通过内部表示编码 $z$ 将 $x$

映射到输出(称为重构) $y$ 。假设 $x \in [0, 1]^d$ 为输入向量, $y \in [0, 1]^d$ 为 $x$ 的近似表示,则传统自编码器模型的定义如下:

$$z = f_{\theta}(x) = s(Wx + b) \quad (3)$$

$$y = g_{\theta'}(z) = s(W'z + b') \quad (4)$$

其中, $z \in [0, 1]^d$ 代表隐藏层的输出, $W$ 代表一个 $d \times d$ 的权重矩阵, $b$ 代表偏置项, $s(\cdot)$ 代表激活函数,如sigmoid, Relu等。若要获得最有效的近似值,通常使损失函数 $Loss$ 的函数值最小, $Loss$ 函数的定义如下:

$$L(x, y) = \|x - y\|^2 \quad (5)$$




图3 自编码器的传统结构

Fig. 3 Traditional architecture of auto encoder

在具体实现中,自编码器的编码部分和解码部分可以由多种深度学习模型构成,如卷积神经网络(CNN)、长短期记忆网络(LSTM)等。利用卷积神经网络实现自编码器的编码与解码部分,并接受部分损坏的输入数据进行模型训练,可以构成卷积去噪自编码(CDAE),其最大优势在于卷积神经网络的局部感知和权值共享。局部感知可以保留二维图像的结构信息;权值共享能够有效降低神经网络需要训练的参数个数,使网络结构的适用性更强。典型CDAE的体系结构含有卷积和池化层的编码器部分,以及具有卷积和上采样的解码器部分,如图4所示。CDAE可采用随机梯度下降算法或自适应梯度下降算法对CDAE模型进行优化。




图4 传统CDAE网络结构

Fig. 4 Traditional architecture of CDAE network

通过对芯片表面缺陷图像进行重构可以得到相对应的正常表面图像,因此重构也可以看作是缺陷修复的过程。文献<sup>[20]</sup>结合内容编码(Context Encoders, CE)网络结构和对抗网络(Generative Adversarial Networks, GAN)对缺失的图像进行重构修复,其中,CE用于学习图像特征和生成图像待修补区域对应的预测图,GAN用于判断预测图来自训练集和预测集的可能性,当生成的预测图与真实图像在图像内容上达到一致,并且GAN的判别器无法判断预测图是否来自训练集或预测集时,就认为网络模型参数达到了最优状态。CE其实是CAE网络的延伸,编码网络与解码网络通过全连接层连接,使解码网络中的每个单元都可以对整个图像内容进行推理。因此本文方法借鉴了CE网络中全连接层的思想,提出

了一种基于卷积去噪自编码器(CDAE)的全连接层卷积去噪自编码器(Fully Connected Layer Convolutional Denoising Auto-Encoders, FCDAE),其结构如图5所示,具体参数将在2.2节中进行详细说明。




图5 FCDAE模型网络结构

Fig. 5 Architecture of FCDAE network model

## 2.2 FCDAE网络结构

FCDAE网络结构由编码器、全连接层、解码器3个部分构成。其中,编码器由4个卷积层和4个池化层构成,解码器由4个反卷积层构成,编码器与解码器是通过全连接层进行连接的。具体参数如下。

1)输入:  $28 \times 28 \times 1$  单通道 png 格式图片。

2)编码器:由4个卷积层和4个池化层组成,每个卷积层后都有一个池化层。第一层卷积层包含了32张特征图,其卷积核大小为  $3 \times 3$ ,特征矩阵大小为  $28 \times 28$ ;池化层包含了32个特征图,特征矩阵大小为  $28 \times 28$ 。第二层卷积层包含了32张特征图,其卷积核大小为  $3 \times 3$ ,特征矩阵大小为  $14 \times 14$ ;池化层包含了32个特征图,特征矩阵大小为  $14 \times 14$ 。第三层卷积层包含了64张特征图,其卷积核大小为  $3 \times 3$ ,特征矩阵大小为  $7 \times 7$ ;池化层包含了64个特征图,特征矩阵大小为  $7 \times 7$ 。第四层卷积层包含了128张特征图,其卷积核大小为  $3 \times 3$ ,特征矩阵大小为  $4 \times 4$ ;池化层包含了128个特征图,特征矩阵大小为  $4 \times 4$ 。此阶段的池化操作采用了均值池化,能够更好地保留芯片表面图像的背景信息。激活函数均采用Relu激活函数。

3)全连接层:节点大小为512的全连接层,采用Relu激活函数。

4)解码器:由4个反卷积层构成,利用最近邻插值算法和卷积实现反卷积功能。第一层反卷积层包含了128张特征图,其卷积核大小为  $3 \times 3$ ,特征矩阵大小为  $4 \times 4$ ;第二层反卷积层包含了64张特征图,其卷积核大小为  $3 \times 3$ ,特征矩阵大小为  $7 \times 7$ ;第三层反卷积层包含了32张特征图,其卷积核大小为  $3 \times 3$ ,特征矩阵大小为  $14 \times 14$ ;第四层反卷积层包含了32张特征图,其卷积核大小为  $3 \times 3$ ,特征矩阵大小为  $28 \times 28$ 。其中,前3个反卷积层的激活函数均采用Relu激活函数,最后一个反卷积层采用Sigmoid激活函数。

5)输出:  $28 \times 28 \times 1$  单通道 png 格式图片。

## 2.3 网络训练

用于模型训练的无缺陷芯片表面图像数据采集于真实生产环境,由合作单位提供,共260张。由于受数据采集条件的影响,芯片表面图像数据通常存在非缺陷噪声。在验证重构

效果时,需要排除原始图像中的非缺陷噪声干扰,因此需要对原始图像做平滑处理。本文采用高斯平滑对原始图像进行去噪处理。因为原始图像尺寸( $196 \times 28$ )与本文网络接受输入的图片尺寸( $28 \times 28$ )不符,所以需要原始图像尺寸进行一定处理。图像尺寸处理方法有分割法和压缩法两种,本文采用分割法对原始图像进行处理,因为在图像检测中考虑的并不是图像的整体性信息,而是局部性,且分割处理能够扩大网络的训练集数据规模。

去噪自编码器常见的加噪方式有对输入的部分随机添加高斯噪声、将输入的部分随机设置为零、添加掩蔽噪声等<sup>[21]</sup>。FCDAE网络通过添加随机的高斯噪声对输入数据进行损坏,经过实验验证发现高斯噪声幅度为0.1时,训练时间较短,且能够取得较好的效果。FCDAE网络模型训练过程中采用的优化算法是自适应梯度下降法。

## 2.4 基于FCDAE网络的图像重构

FCDAE网络接受受损数据作为输入数据,通过输出可以预测原始的未损坏数据,因此本节对FCDAE网络重构有损输入的能力进行验证。图6给出了单个子图像的输入与输出重构之间的对比结果。分别使用正常图像数据和缺陷数据作为输入,从图6中正常图像和重构图像的灰度对比分布图可以看出,二者在灰度像素分布上存在一些差异,但是整体上像素分布图是类似的;缺陷图像的重构结果基本不含图中缺陷图像内红色标记的缺陷区域。




图6 子图像数据重构示例(电子版为彩色)

Fig. 6 Examples of sub-image data reconstruction

芯片表面图像为灰度图像,背景单一,导致直观上很难分辨出输入与重构输出的差异,因此本文引入了伪彩图,即将灰度图像转变为彩色图像,从而能够更直观地分辨出两者之间的差异。图7展示了正常图像、高斯噪声图像、去噪后图像、模拟缺陷图像、模拟缺陷图像重构输出及其相应的伪彩图对比,其中高斯噪声图像、模拟缺陷图像是在正常图像的基础上添加高斯噪声或模拟缺陷形成的。

通过对比FCDAE网络重构高斯噪声图像或模拟缺陷图像的结果与正常图像,可以看出FCDAE网络的去噪能力和重构缺陷图像的效果。由图7可知,去噪后图像基本上不含有噪声;对比去噪后图像与正常图像的伪彩图发现,二者在灰度像素分布上存在一些不同,但基本分布是相似的;从模拟缺陷重构图像伪彩图可以看出,重构结果不含有模拟缺陷,FCDAE网络能够很好地重构缺陷区域相对应的正常区域;与正常图像对比可以发现,模拟缺陷的重构结果虽然存在一些误差,但是像素分布基本上相似。




图7 FCDAE网络输入与输出的对比

Fig. 7 Comparison of input and output in FCDAE network

综上所述,FCDAE网络在有损数据的重构方面具有鲁棒性。FCDAE网络对真实芯片表面缺陷图像的重构效果将在第5节说明。

### 3 基于重叠区域的残差图生成

通过FCDAE网络重构缺陷图像对应的正常图像时,无法保证100%重构原始图像,其重构的像素值在正常像素值邻域内波动,导致重构时引入随机误差。非缺陷区域的残差值可能为正也可能为负,具有随机性;缺陷区域的像素值通常高于或低于非缺陷区域,因此缺陷区域的残差值要么为正,要么为负,具有一致性。为了消除随机误差的影响,本文采用重叠区域的思想重构图像块,使区域像素点能够被重构多次,然后对重叠区域进行叠加处理,使非缺陷区域的残差值正负情况的随机性得到一定的消弱和缺陷区域正负情况的一致性得到增强,加大了缺陷区域与非缺陷区域的对比度,使得缺陷分割更为轻松。

#### 3.1 重叠区域划分

重叠区域划分是基于重叠区域的残差图生成的关键步骤。假设块图像的大小为 $w \times h$ , $w$ 方向上步幅间隔为 $s_w$ , $h$ 方向上步幅间隔为 $s_h$ ,由尺寸为 $W \times H$ 的图像划分生成的子图像集可表示为 $\lceil n_p, n_c, w, h \rceil$ ,其中, $n_p$ 指子图像集中块的数目, $n_c \in \{1, 3\}$ 指图像通道的数量, $\lceil \cdot \rceil$ 为向上取整函数。 $n_p$ 的计算公式如式(6)所示:

$$n_p = \left\lceil \left[ \frac{W-w}{s_w} + 1 \right] \times \left[ \frac{H-h}{s_h} + 1 \right] \right\rceil \quad (6)$$

通过对步长 $s_w$ 和 $s_h$ 的设置,可以决定两个相邻重叠区域的大小,如图8所示。本文进行重叠区域划分时,以原始图像的左上顶点为起始点,按照从左往右、从上到下的方向依次进行重叠区域划分,其中 $s_w = s_h$ ,在水平方向上按照图8(b)所示的方式划分,在垂直方向上按照图8(c)所示的方式划分。

假设原始图像为 $X$ ,重叠区域划分集合为 $\beta(x_k | k=1, 2, \dots, n_p)$ ,则:

$$K = \frac{(w-s_w)(h-s_h)}{w \times h} \quad (7)$$

$$o_{ij} = \beta(x_i) \cap \beta(x_j), i, j = 1, 2, \dots, n_p \quad (8)$$

$$X = \beta(x_1) \cup \beta(x_2) \cup \dots \cup \beta(x_{n_p}) \quad (9)$$

其中, $K$ 表示相邻区域的重叠区域所占单个区域的比例,与步长的关系如图9所示; $o_{ij}$ 表示块 $i$ 与块 $j$ 之间重叠的区域集合; $x_k$ 表示第 $k$ 个子图像。





图8 相邻重叠区域划分

Fig. 8 Division of adjacent overlapping areas



注:其中 $s = s_w = s_h$

图9 相邻区域的重叠区域所占比例 $K$ 与步长 $s$ 的关系变化趋势图Fig. 9 Trend diagram of relationship between ratio  $K$  of overlapping area of adjacent area and tep size  $s$ 

#### 3.2 单区域的残差生成

通过重叠区域划分得到子图像集合 $\beta(x_k | k=1, 2, \dots,$

$n_p$ ),然后通过 FCDAE 网络重构  $\beta(x_k)$  获得重构图像集合  $\beta(x_k')$ ,接着获取重构图像  $\beta(x_k')$  与输入  $\beta(x_k)$  之间的残差。为了消除 FCDAE 网络重构输出时引入的随机噪音,在单个块图像的残差获取中,应当保留残差的原始情况。假设  $\vartheta(x_k | k=1,2,\dots,n_p)$  表示残差集合, $x_k$  指第  $k$  块输入图像, $x_k'$  表示第  $k$  块输入图像的重构图像,则:

$$\vartheta(x_k) = x_k' - x_k \quad (10)$$

### 3.3 重叠区域的残差图合成

通过式(10)可以获取 FCDAE 网络输出和输入的单区域残差信息。因为在获取单区域时采用了重叠区域策略,所以在残差图合成时采用对齐重叠区域的像素点策略进行重叠区域残差图合成。根据  $x_k$  在原始图像中的位置,可以得知  $\vartheta(x_k)$  在原始图像中的位置,假设  $x_k$  中像素的坐标为  $(m,n)$ ,所对应的原始图像中的位置坐标为  $(M,N)$ ,则合成公式如下:

$$M = i \times s_w + m \quad (11)$$

$$N = j \times s_h + n \quad (12)$$




图 10 不同步长重叠区域残差图合成效果对比

Fig. 10 Comparison of synthetic effects of residual map of in non-synchronous long overlapping regions

## 4 基于残差图的缺陷检测

本节主要介绍残差图的缺陷检测,它是本文方法的关键步骤之一。图像分割是机器视觉研究中的一个经典难题。精致的图像分割能将图像中有效的信息提取出来。通过对重叠区域的残差图进行增强处理,加大了缺陷区域与非缺陷区域的对比度。与原始图像相比,分割残差图更为容易,可以采用阈值分割法对其进行有效的分割。阈值的选取,是决定分割效果的关键因素,本文采用最大类间方差法(Otsu)来获取阈值。

最大类间方差法是由 Otsu<sup>[22]</sup> 于 1979 年提出的一种自动求取阈值的方法,又被称为大律法(简称 Otsu)。利用图像的灰度特性,将图像分成背景和目标两个部分。背景与目标之间的类间方差越大,说明构成图像的两部分之间的差别越大,因此可以将背景与目标的类间方差最大值作为阈值的选取准则。

通过最大类间方差法获得分割阈值  $T$ 。对于重构残差图

$$r_{W \times H}(M, N) = \sum_{k=1}^{n_p} (\vartheta(x_k)(m, n) + r_{W \times H}(M, N)) \quad (13)$$

其中, $i$  和  $j$  分别为图像块  $x_k$  在原始图像中  $W$  和  $H$  方向上提取的顺序次数, $r_{W \times H}$  的初始值为全零矩阵。

图像块的提取步长  $s_w$  和  $s_h$  的大小对相邻块的提取区域有重要的影响。步长  $s_w$  和  $s_h$  的值越大,相邻块的重叠区域就越少,叠区域的比率  $K$  就越小,因此实验验证了  $s = s_w = s_h$  的值为 1,2,4,7,14,28 时对构建残差图的影响,重建残差图如图 10 所示。

从构建的残差图中可以看出,随着  $s$  值的逐渐增大,残差图中的缺陷区域与非缺陷区域对比度明显减弱,同时残差图中引入的噪音逐渐减少。当  $s=1$  时,构造的残差图和热度图的缺陷区域与非缺陷区域的对比度最高。同时,这也反映出了区域重叠可以增强残差图中缺陷区域与非缺陷区域的对比度,减弱非缺陷噪音的干扰。在后文的分割实验中, $s=1$  将用于图像块提取。

$r$  的分割处理如下:

$$\delta(i, j) = \begin{cases} 255, & r(i, j) \leq T \\ 0, & r(i, j) > T \end{cases} \quad (14)$$

其中, $r(i, j)$  对应残差图中位置  $(i, j)$  处的像素值, $T$  表示此残差图的阈值, $\delta(i, j)$  表示残差图分割后位置  $(i, j)$  对应的像素值。

分割阈值是区分缺陷区域与非缺陷区域的一个关键参数,它直接影响缺陷的检测性能。不同的输入图片会得到不同的分割阈值,根据得到的分割阈值对重建残差图进行分割,能有效地分割出非缺陷区域和缺陷区域。图 11 中,原始图片中红色标记的区域为缺陷区域,残差图是通过 FCDAE 网络重构和基于重叠区域方法生成的,然后利用最大类间方差法分别获取两者的分割阈值进行分割处理。通过对比原始图像分割结果和残差图分割结果可以发现,基于残差图能够有效地分割出缺陷区域。




图 11 分割结果(电子版为彩色)

Fig. 11 Segmentation results

## 5 实验

本节主要验证了本文提出的芯片表面缺陷检测方法,并对验证实验中的数据进行了简单介绍。

### 5.1 实验数据集

本文所用数据均由论文合作单位——合肥图讯电子科技有限公司提供(合肥图讯电子科技有限公司<sup>1)</sup>专注于半导体芯片检测设备的研发),合计提供了260幅正常图片用于网络训练,60幅包含缺陷的图片用于本文方法的测试。图12给出了图片样例,所提供测试图片既包含很明显的缺陷,又有特征很弱的缺陷,如图12(b)所示。用于测试的缺陷图片来自公司多年在实际生产中所积累的数据库,由专业人员挑选,确保涵盖了生产中常见的缺陷,因此具有代表性。



图12 芯片表面图像示例

Fig. 12 Examples of chip surface images

### 5.2 高斯平滑去噪

为了排除非缺陷噪声的干扰,本文采取高斯平滑对芯片表面图像数据非缺陷噪声进行去噪处理。如果高斯平滑过度,可能对芯片表面的弱缺陷造成影响,使弱缺陷被当作非缺陷噪声而被平滑处理,最终无法检测出弱缺陷。高斯平滑的关键在于高斯核 $\sigma$ 的选取。合适的 $\sigma$ 值有助于抑制非缺陷噪声,削弱非缺陷噪声对缺陷区域的影响。因此,本文对 $\sigma$ 的取值进行了验证。图13为 $\sigma$ 的大小为1,2,3的重建残差图,其中原始图像中红色标记的为原始缺陷区域。从图中可以发现,当 $\sigma=1$ 时,分割效果较差,非缺陷区域引入了较多的噪声,非缺陷噪声被抑制;当 $\sigma=2$ 和 $\sigma=3$ 时,非缺陷区域基本不含有噪声,能有效分割出缺陷区域,但是当 $\sigma=3$ 时,高斯平滑过度,使得缺陷区域与原始缺陷相比发生了严重的变形。综上所述,为了能够有效地分割出缺陷区域并保证缺陷区域不发生严重变形,本文采用高斯核 $\sigma=2$ 的高斯平滑来进行去噪处理。




图13 不同 $\sigma$ 大小高斯平滑的重建残差图及相应分割对比  
(电子版为彩色)

Fig. 13 Reconstruction residuals of Gaussian smoothing of different  $\sigma$  sizes and comparison of corresponding segmentation

### 5.3 缺陷检测

本节对62张含有缺陷的芯片表面数据进行了缺陷检测,

有效分割图片数据有56张,准确率达到90%,在缺陷与背景对比度低和缺陷较小等弱缺陷的数据中取得了较好的分割效果,检测结果如图14所示,其验证了本文方法在芯片表面弱缺陷检测中有显著的效果。本文的检测结果得到了合作单位的认可。

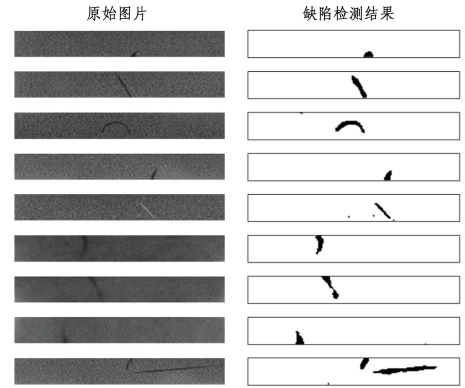


图14 缺陷检测结果

Fig. 14 Defect detection results

但是,在实验中也遇到过缺陷分割错误的情况,如图15所示,红圈标记的是原始缺陷区域。为了区分缺陷区域与非缺陷区域的差异,引入了热度图。在热度图中,像素值越高,颜色越趋于红色,像素值越低,颜色趋于蓝色,因此热度图可以更加直观地反映出两者之间的差异。其中,第一行的原始输入图像中的缺陷区域不明显,缺陷区域像素宽度仅为1~2个像素,而非缺陷区域中也存在类似的像素值,虽然残差图中也能构建出缺陷区域,但是与非缺陷区域的差异不是很明显,导致在缺陷分割时没有分割出缺陷区域;而第二行中的缺陷区域也没有被完全分割出来,原因与前者类似,缺陷区域过于狭窄,只有1~2个像素,其灰度值低于噪声,使重构无缺陷图像时受到影响,导致在后续的自动阈值分割阶段产生影响,使分割出的缺陷出现断裂。因此,本文方法还存在有待改进的地方。




图15 重建残差图与分割效果较差示例(电子版为彩色)

Fig. 15 Examples of poor reconstruction residuals and poorly split effects

**结束语** 本文提出全连接层卷积去噪自动编码器(FC-DAE)方法,用于基于无监督学习的缺陷检测。该方法基于CDAE网络构建残差图来区分缺陷区域与非缺陷区域,通过分析和实验证明,利用无监督学习的优势,可避免人工标记数据,节约成本;基于重叠区域的残差图获取,增强了缺陷区域与非缺陷区域的对比,使芯片表面缺陷能够很容易被自动阈

<sup>1)</sup> <http://www.image-x.com.cn/>

值分割方法分割出来。但是,本文方法还存在不足,网络模型和分割算法还有待改进,使缺陷检测能够取得更好的效果。目前,本文方法只能检测出缺陷,而无法识别缺陷的类型,因此今后的研究方向是使用分类器对检测出的缺陷进行分类,并对缺陷类型进行判断。

### 参 考 文 献

- [1] CHEN K. Research on key techniques for integrated circuit chip surface defects vision detection[D]. Nanjing: Southeast University, 2016.
- [2] RADOVAN S, PAPAPOPOULOS G D, GEORGOUDAKIS M, et al. Vision system for finished fabric inspection[C]// Machine Vision Applications in Industrial Inspection X. San Jose, California; International Society for Optics and Photonics, 2002: 97-104.
- [3] SILVÉN O, NISKANEN M, KAUPPINEN H. Wood inspection with non-supervised clustering[J]. Machine Vision and Applications, 2003, 13(5/6): 275-285.
- [4] SINGHKA D K H, NEOGI N, MOHANTA D. Surface defect classification of steel strip based on machine vision[C]// 2014 International Conference on Computer and Communications Technologies (ICCT). Hyderabad, India; IEEE, 2014: 1-5.
- [5] CHIOU Y C, LIN C S, CHIOU B C. The feature extraction and analysis of flaw detection and classification in BGA gold-plating areas[J]. Expert Systems with Applications, 2008, 35(4): 1771-1779.
- [6] DONG X F, HAN Z Y, LIAO S Y, et al. Study on Semiconductor Surface Defect Detection Based on Machine Vision[J]. Metrology & Measurement Technology, 2014, 34(5): 22-24, 49.
- [7] SU L, SHI T, DU L, et al. Genetic algorithms for defect detection of flip chips[J]. Microelectronics Reliability, 2015, 55(1): 213-220.
- [8] FENG L, GONG Z H. An algorithm for chip surface defect detection based on sequential similarity and light source automatic adjustment[J]. Modern Electronics Technique, 2017(5): 58-62.
- [9] BENGIO Y, LECUN Y. Scaling learning algorithms towards AI [C] // Large-Scale Kernel Machines. Hayward Street, Cambridge; MIT Press, 2007: 321-359.
- [10] BENGIO Y, DELALLEAU O. On the expressive power of deep architectures [C] // International Conference on Algorithmic Learning Theory. Germany; Springer-Verlag, 2011: 18-36.
- [11] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks [J]. Science, 2006, 313(5786): 504-507.
- [12] FENG C, LIU M Y, KAO C C, et al. Deep Active Learning for Civil Infrastructure Defect Detection and Classification [M] // Computing in Civil Engineering 2017. Berlin; Springer, 2017: 298-306.
- [13] ZHANG A, WANG K C P, LI B, et al. Automated pixel-level pavement crack detection on 3D asphalt surfaces using a deep-learning network [J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32(10): 805-819.
- [14] REN R, HUNG T, TAN K C. A generic deep-learning-based approach for automated surface inspection [J]. IEEE transactions on cybernetics, 2018, 48(3): 929-940.
- [15] WANG X B, LI J, YAO H M, et al. Solar Cells Surface Defects Detection Based on Deep Learning [J]. Pattern Recognition and Artificial Intelligence, 2014, 27(6): 517-523.
- [16] LI Y, ZHAO W, PAN J. Deformable patterned fabric defect detection with Fisher criterion-based deep learning [J]. IEEE Transactions on Automation Science and Engineering, 2017, 14(2): 1256-1264.
- [17] MEI S, YANG H, YIN Z. An unsupervised-learning-based approach for automated defect inspection on textured surfaces [J]. IEEE Transactions on Instrumentation and Measurement, 2018, 67(6): 1266-1277.
- [18] VINCENT P, LAROCHELLE H, BENGIO Y, et al. Extracting and composing robust features with denoising autoencoders [C] // Proceedings of the 25th International Conference on Machine Learning. New York; ACM, 2008: 1096-1103.
- [19] VINCENT P, LAROCHELLE H, LAJOIE I, et al. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion [J]. Journal of machine learning research, 2010, 11(12): 3371-3408.
- [20] PATHAK D, KRAHENBUHL P, DONAHUE J, et al. Context encoders: Feature learning by inpainting [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA; IEEE, 2016: 2536-2544.
- [21] STRUB F, MARY J, GAUDEL R. Hybrid Collaborative filtering with autoencoders [J]. arXiv:1603.00806, 2016.
- [22] OTSU N. A threshold selection method from gray-level histograms [J]. IEEE Transactions on Systems, Man, and Cybernetics, 1979, 9(1): 62-66.



**LUO Yue-tong**, born in 1978, Ph.D, professor, master supervisor, is member of China Computer Federation (CCF). His main research interests include visual analytic, computer vision and automated optical inspection.