

ValidFlow: 基于标准化流的无监督图像缺陷检测

张兰尧¹, 陈晓玲¹, 张达敏², 岑翼刚³, 张琳娜¹, 黄彦森^{4,5}

(1. 贵州大学机械工程学院, 贵阳 550025; 2. 贵州大学大数据与信息工程学院, 贵阳 550025; 3. 北京交通大学计算机与信息技术学院, 北京 100044; 4. 贵州大学土木工程学院, 贵阳 550025; 5. 贵州联建土木工程质量检测监控中心有限公司, 贵阳 550016)

摘要: 基于标准化流的 CS-Flow 方法在缺陷检测领域取得了不错的效果, 但其重复堆叠单一耦合块的方式增大了网络的复杂度。为此, 本文提出了由特征平行流 (Feature advection flow, FA flow) 与特征混合流 (Feature blending flow, FB flow) 两种耦合块堆叠构成的网络 ValidFlow, 其中 FA flow 内部的子网络去掉了上下采样的捷径分支, 并引入深度可分离卷积; FB flow 内部的子网络在 3 个尺度上进行跨尺度融合。这样的设置使得 ValidFlow 在参数量减少的同时保证了信息的充分混合。在 MVTec AD、MTD 和 DAGM 数据集上与已有方法的对比结果显示, 在 MVTec AD 数据集上, ValidFlow 在 15 个类别中的平均 AUROC 为 99.2%, 在 4 个类别上的 AUROC 均为 100%; 在 MTD 数据集上获得了 99.6% 的 AUROC; 相比于 CS-Flow, ValidFlow 的参数量减少了 207.61M, 推理速度 FPS 提升了 22; 在 DAGM 数据集上, 10 个类别的平均 AUROC 为 99.0%, 性能上非常接近有监督的方法。

关键词: 标准化流; 特征平行流; 特征混合流; 深度可分离卷积; 跨尺度

中图分类号: TP391 **文献标志码:** A

ValidFlow: Unsupervised Image Defect Detection Based on Normalizing Flows

ZHANG Lanyao¹, CHEN Xiaoling¹, ZHANG Damin², CEN Yigang³, ZHANG Linna¹, HUANG Yansen^{4,5}

(1. School of Mechanical Engineering, Guizhou University, Guiyang 550025, China; 2. College of Big Data and Information Engineering, Guizhou University, Guiyang 550025, China; 3. School of Computer and Information Technology, Beijing Jiaotong University, Beijing 100044, China; 4. College of Civil Engineering, Guizhou University, Guiyang 550025, China; 5. Guizhou Lianjian Civil Engineering Quality Inspection Monitoring Center Co. Ltd., Guiyang 550016, China)

Abstract: The CS-Flow method based on normalizing flows has achieved good results in the field of defect detection, but its way of repeatedly stacking single coupling blocks increases the complexity of the network. Therefore, we propose a network ValidFlow composed of two coupling blocks stacking: Feature advection flow (FA flow) and feature blending flow (FB flow). In the subnetwork of FA flow, the shortcut branch of up and down sampling is removed and depth-separable convolution is introduced. The subnetworks within FB flow are fused across scales at three scales. This allows ValidFlow to reduce the number of parameters while keeping the information well mixed. Compared with the existing methods on

基金项目: 国家自然科学基金 (62062021); 贵阳市科技计划项目 (筑科合同 [2023] 48-11)。

收稿日期: 2022-08-17; **修订日期:** 2023-02-07

MVTec AD, MTD and DAGM datasets, it can be seen that on MVTec AD datasets, the average AUROC of ValidFlow in 15 categories is 99.2%, and the AUROC of ValidFlow in four categories is 100%. On the MTD dataset, AUROC achieves 99.6%. At the same time, compared with CS-Flow, ValidFlow has 207.61M fewer parameters and 22 higher reasoning speed FPS. On the DAGM dataset, the average AUROC of the 10 categories is 99.0%, which is very close to the monitored method in terms of performance.

Key words: normalizing flows; feature advection flow (FA flow); feature blending flow (FB flow); depth-separable convolution; across scales

引言

在工业产品生产制造中,为确保产品质量和使用安全,缺陷产品必须要被检测出来,这使得缺陷检测对于改进自动产品质量检测具有重要的意义,可以在很大程度上减少人工劳动、提高检测效率。近年来,机器视觉与深度学习技术在缺陷检测领域得到了广泛应用^[1-6],但是由于缺陷产品出现的概率小,甚至在极端情况下没有可用的缺陷样本,使得在实践中很难收集和标注大量的缺陷样本用于监督学习^[7-11]。相反,正常样本却极易获得,因此提出无监督缺陷检测来解决此问题。基于无监督的深度学习缺陷检测方法仅需要易于获取的正常样本用于模型训练,无需使用真实缺陷样本,在推理阶段比较测试样本与模型间的像素或特征的差异性来实现缺陷的检测与定位^[12-13]。

异常检测领域的研究大多集中在类内和类间方差大的数据上,然而在缺陷检测领域,缺陷样本与正常样本的背景相同,且缺陷像素在整个图像中占比较小,可能造成数据集呈现较小的类内和类间方差,使得许多异常检测算法并不能应用于缺陷检测。基于生成对抗网络(Generative adversarial network, GAN)^[14-15]或自动编码器^[16-18]的方法在此类数据集上往往都表现得较差。因此,本文将目光转向了基于密度表示的方法,该方法主要是通过计算测试图像的特征分布与网络所学习到的正常图像的特征分布之间的距离来进行缺陷的检测与定位。在基于密度表示的方法里,标准化流模型表现出了强劲的性能,最近的一些工作^[19-20]开始使用标准化流模型去检测缺陷,并取得了不错的效果。但是原始的一维标准化流方法需要将输入的二维特征展平成一维特征向量来估计其分布,破坏了原有的图像位置关系,导致无法进行像素级定位,极大地限制了流模型的能力。Rudolph等^[21]提出的CS-Flow则摒弃了特征展平的操作,直接利用分类网络抽离二维特征,并且在耦合块内部提供仿射变换参数的模块中引入二维卷积,同时利用了上、下采样来进行跨尺度信息融合,这使得网络获得了丰富的语义信息,同时解决了无法进行缺陷像素级定位的问题。但由于耦合块内部的子网络过于复杂,网络的复杂度也随之增大。

为此,本文提出了新的方法 ValidFlow,它由若干个特征平行流(Feature advection flow, FA flow)和特征混合流(Feature blending flow, FB flow)组合的模块重复堆叠而成,FA flow 用于减少参数数量,FB flow 用于充分混合特征信息,具体结构详见第2节。首先通过特征提取器提取特征,再将其特征信息数据分布 $p_X(x)$ 通过流模型映射到一个潜在的预定义简单分布 $p_Z(z)$ 上,推理阶段将输出的二维特征 z 上每个位置的概率值作为异常评分。ValidFlow 中生成的隐空间向量 z 直接被解释为输入数据 x 的可能性。因为网络映射是可逆的,因此,隐空间中具有高可能性的区域代表正常样本,而输入的缺陷样本则被映射到学习的正常数据分布之外。

综上所述,本文的主要贡献有:

(1)在CS-Flow网络的基础上提出了一种新的基于标准化流的网络 ValidFlow,用于缺陷检测。

(2)提出了两种新的耦合模块,即FA flow和FB flow。在FA flow中,取消了内部子网络的跨尺度分支,并引入深度可分离卷积来减少网络模型参数;在FB flow中,参照CS-Flow内部子网络的部分设置,增加两条跨尺度分支来充分混合信息,同时在两个子网络中均引入CBAM注意力机制来优化网络。

(3)在MVTec AD、MTD和DAGM数据集上进行了多组对比实验,验证了所提方法的有效性和必要性。相较于已有方法,本文方法取得了最优的性能。

1 研究现状

1.1 异常检测

现有的异常检测方法大致分为3类:基于重建的方法、基于分类的方法和基于密度表示的方法。

1.1.1 基于重建的方法

基于重建的方法仅在正常图像样本上进行模型训练,使其能够很好重建正常图像,在测试阶段对于图像的缺陷区域则会产生较大的重建误差,以此达到缺陷检测与定位的效果。An等^[22]提出了基于变分自编码器重构概率的异常检测方法,通过计算给定数据的重构概率来判断该数据的异常程度;唐小煜等^[3]提出了一种改进的基于U-Net的缺陷检测方法SERes-Unet,该方法使用残差结构来解决卷积过程中的梯度消失和结构信息损失带来的影响,并引入注意力机制来对输入特征图进行权重调整,以此提升网络性能;Yan等^[23]提出了一种基于语义上下文的异常检测网络(Semantic context based anomaly detection network, SCADN),通过设计多尺度条纹掩膜来从正常样本图像中移除一部分区域,并重建缺失的区域以匹配输入图像。值得注意的是,该文在多个尺度和条纹的方向进行掩膜的设计,并以此生成各种训练样本,以获得丰富的上下文信息。

1.1.2 基于分类的方法

基于分类的方法一般利用CNN网络强大的特征提取能力,将输入图像送入分类网络中,网络输出其对应的类别和该类别的置信度。胡佳美等^[2]提出了双向二维主成分分析和改进的卷积神经网络相结合的缺陷识别方法,利用双向二维主成分分析法提取主要特征,再通过改进的AlexNet网络进行缺陷分类。Shang等^[1]提出了通过对钢轨图像进行定位和分类的两阶段钢轨缺陷检测方法。在第一阶段,结合传统图像处理方法,获得以轨道为中心的裁剪图像;在第二阶段中,将上阶段获得的裁剪图像送入Inception V3网络提取特征以进行轨道图像分类。Nagata等^[24]提出了一种SeeNet(NET with SVMs to classify sample images)网络,该网络由两个分支组成。第一分支采用AlexNet进行特征提取,分类器采用SVM,该分支主要对正常样本和缺陷样本进行二分类;第二分支则是对7个缺陷类别进行分类。这种二分支的网络结构用于多类别的分类任务,能够充分利用正负样本不均衡的特点来挖掘出两者间的差异。

1.1.3 基于密度表示的方法

基于密度表示的方法主要依赖于从ImageNet数据集上预训练的分类网络获得的有用的特征向量,训练阶段通过输入正常图像获得正常样本数据的分布,推理时通过计算异常样本数据分布与正常样本数据分布之间的距离来进行异常的检测与定位。Cohen等^[25]提出了一种新的异常分割方法SPADE(Semantic pyramid anomaly detection),该方法利用最近邻(k -nearest neighbor, KNN)在图像级上获得与一个异常图像最相似的 K 个正常图像,再利用检索出来 K 个正常图像在神经网络中不同层下获得特征金字塔信息进行对齐,该方法在缺陷的检测与定位中取得了不错的效果。Rippel等^[26]将预训练的特征建模为单峰的高斯分布,并利用马氏距离进行异常评估。Defard等^[27]则进一步对该方法进行了改进,并提出了一种新的网络PaDiM。该网络采用预训练的卷积神经网络不同语义层之间的特征进行patch嵌入,同时利用多元高斯分布获得正常样本的概率密度表示。

1.2 标准化流

标准化流(Normalizing flow, NF)^[28]是一种生成模型,它利用可逆的仿射变换将数据转换为可跟踪的分布,并且数据的映射是双向的,这一特点使得该模型可以进行双向的训练和评估。在前向传播阶段,NF将数据映射到预定义分布的隐空间,以计算在给定分布下数据的概率密度;在反向传播阶段,从预定义的分布中采样数据,再映射回原始空间以生成数据。Rudolph等^[20]提出了DifferNet网络,利用卷积神经网络提取具有描述性的特征信息,第一次使用标准化流来进行概率密度评估。然而该网络只利用了生成的最后特征层,且该层是平均池化后的向量,缺乏重要的上下文语义信息和位置信息,只能应用于图像级检测,并不能进行像素级的定位;文献[21]中提出的标准化流方法CS-Flow采用了多尺度的特征,并引入完全卷积,在检测和定位上都取得了较好效果。CS-Flow耦合块内部提供放射变换数参数的子网络中将3个尺度的特征进行卷积计算,并通过上、下采样策略来充分混合信息,但采用这样的方式会加重训练负担,降低了推理速度,从而造成不必要的资源浪费。

为了缓解这些问题,本文提出了新的标准化流方法 ValidFlow。该方法完全避免使用全连接层和压缩层,保持二维特征信息在空间上的排列,以此实现缺陷的定位,同时摒弃了CS-Flow中使用单一耦合块进行重复堆叠的方式,采用参数量少的FA flow和可充分混合信息的FB flow两个耦合块组合的模块重复堆叠。因此所提的方法不仅能够将不同尺度信息充分混合,获得丰富的语义信息,而且可以减少参数量,降低训练时间,提升推理速度,也使得本文的网络能够处理高维度的特征映射。

2 方 法

如图1所示,本文的方法主要由特征提取器和ValidFlow流模型两部分组成,其中ValidFlow由 n 个FA flow和FB flow组合的模块构成,特别注意的是FA flow内部的子网络均设置为 $r1$,FB flow内部的子网络均设置为 $r2$ 。在训练阶段,本方法旨在学习网络模型 $P = \{P_\theta, \theta \in \Theta\}$ 的参数 θ ,将所有正常图像数据 x 通过特征提取器提取主要特征 y ,再利用ValidFlow流模型将其映射到相同的分布 $p_z(z)$;在推理阶段,当检测到缺陷图像或异常像素时,网络将其映射到分布之外,以此达到缺陷的检测与定位。

对于特征提取器的选择,本文沿用了CS-Flow中的设置,采用EfficientNet-B5中第36层的输出作为本方法的特征提取器。

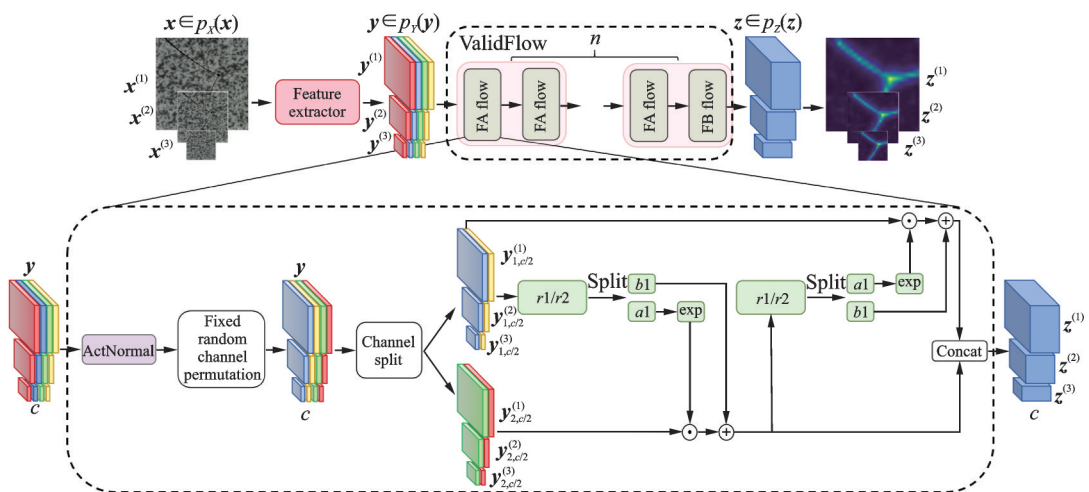


图1 ValidFlow网络结构图

Fig.1 Structural diagram of ValidFlow network

如图1所示,缺陷检测整体流程为 $X \rightarrow Y \rightarrow Z$,其中, $X \rightarrow Y$ 使用预训练的分类网络来提取特征,在网络训练过程中,该部分进行了固定设置,即不参与网络的训练。 $f: Y \rightarrow Z$ 使用双向可逆映射,将 $\mathbf{y} \in p_Y(\mathbf{y})$ 图像特征投影到隐变量 $\mathbf{z} \in p_Z(\mathbf{z})$ 中。对于这个双向可逆函数,使用变量公式来定义模型在 \mathbf{y} 上的分布,即

$$p_Y(\mathbf{y}) = p_Z(\mathbf{z}) \left| \det \left(\frac{\partial \mathbf{z}}{\partial \mathbf{y}} \right) \right| \quad (1)$$

可以从 $p_Z(\mathbf{z})$ 估计图像特征的对数似然

$$\log p_Y(\mathbf{y}) = \log p_Z(\mathbf{z}) + \log \left| \det \left(\frac{\partial \mathbf{z}}{\partial \mathbf{y}} \right) \right| \quad (2)$$

在本文方法中,将映射后的隐空间 Z 的分布定义为标准的高斯分布,即 $\mathbf{z} \sim N(0, 1)$,且训练的目标为最小化 $-\log p_Y(\mathbf{y})$,故目标函数为

$$-\log p_Y(\mathbf{y}) = \frac{\|\mathbf{z}\|_2^2}{2} - \log \left| \det \left(\frac{f_\theta(\mathbf{y})}{\partial \mathbf{y}} \right) \right| \quad (3)$$

式中: $\left| \det \left(\frac{f_\theta(\mathbf{y})}{\partial \mathbf{y}} \right) \right|$ 为双向可逆流模型 $\mathbf{z} = f_\theta(\mathbf{y})$ 的雅可比矩阵行列式的绝对值; θ 为二维流模型的参数。

在训练过程中,ValidFlow的目标是最小化 $-\log p_Y(\mathbf{y})$,因此,缺陷图像比正常图像的特征具有更低对数似然 $\log p_Y(\mathbf{y})$,异常图像的特征会映射到分布之外,本文采用这种似然性作为异常评分。

在实际实现中,本文所提网络的详细结构如图1所示,ValidFlow主要由可逆的FA flow和FB flow组合的模块重复堆叠若干个而成。每个flow内部在3个尺度上执行仿射变换,输入的3个尺度图像特征信息为 $\mathbf{y}^{(i)} (i=1, 2, 3)$,其通道维度为 c ,该张量先经过ActNorm(Activation normalization)进行预处理,使用每个通道的标度和偏差参数执行激活的仿射变换,参数初始化后,其标度和偏差参数可作为网络的训练参数送入网络训练。经过处理后的特征信息 $\mathbf{y}^{(i)}$ 在通道维度被随机打乱,并均分为 $\mathbf{y}_{1,c/2}^{(i)}$ 和 $\mathbf{y}_{2,c/2}^{(i)}$ 两部分,各部分通过对应的尺度参数 a_1, a_2 和位移参数 b_1, b_2 来进行仿射变换,以此获取对应的输出 $\mathbf{y}_{1,c/2}'^{(i)}$ 和 $\mathbf{y}_{2,c/2}'^{(i)}$ 。最后沿通道维度将两部分张量进行拼接,获得输出 \mathbf{z} ,其通道数恢复为 c 。上述过程对应的公式分别为

$$\mathbf{y}_{1,c/2}, \mathbf{y}_{2,c/2} = \text{split}(\mathbf{y}) \quad (4)$$

$$\mathbf{y}_{2,c/2}' = e^{a(\mathbf{y}_{1,c/2})} \odot \mathbf{y}_{2,c/2} + b(\mathbf{y}_{1,c/2}) \quad (5)$$

$$\mathbf{y}_{1,c/2}' = e^{a(\mathbf{y}_{2,c/2})} \odot \mathbf{y}_{1,c/2} + b(\mathbf{y}_{2,c/2}) \quad (6)$$

$$\mathbf{z} = \text{concat}(\mathbf{y}_{1,c/2}', \mathbf{y}_{2,c/2}') \quad (7)$$

式中: $\text{split}()$ 和 $\text{concat}()$ 函数沿通道维度执行均分和拼接操作; \odot 代表逐像素相乘; $a(\bullet)$ 和 $b(\bullet)$ 可以设置为任意复杂的函数来学习仿射变换的两个参数。这两个函数在最初的标准化流方法中由两个全连接网络来实现,需要将二维特征压缩为一维,破坏了特征图中的原始位置信息,无法对缺陷进行定位。在文献[20]中提出的CS-Flow网络提供的方法解决了此类问题,但它在每个耦合块内部的子网络中都采用了3个尺度的信息混合,一定程度上增加了网络训练负担,降低了推理速度。因此,本文提出了新的设置,具体实现子网络模块 $r1$ 和 $r2$ 的结构以及详细参数设置如图2所示,两子网络对特征信息进行处理时,首先通过隐藏层以增加通道数量,其最后输出层均引入了CBAM^[29]注意力机制,让网络去关注更为重要的特征信息。与 $r2$ 不同的是,在 $r1$ 中取消了上下采样策略,让各尺度特征信息平行通过子网

络,并不进行跨尺度融合,以此减少网络复杂度,同时采用深度可分离卷积(DW+PW)^[30]代替普通卷积来减少参数数量,提升推理速度;在 $r2$ 中,通过双线性上采样和跨步卷积来调整不同尺度的特征图大小,然后通过逐像素求和进行特征信息融合,相较于CS-Flow中的子网络设置,增加了两条1、3尺度的分支,即 $r2$ 中红色箭头所示,以此达到充分混合信息的效果。

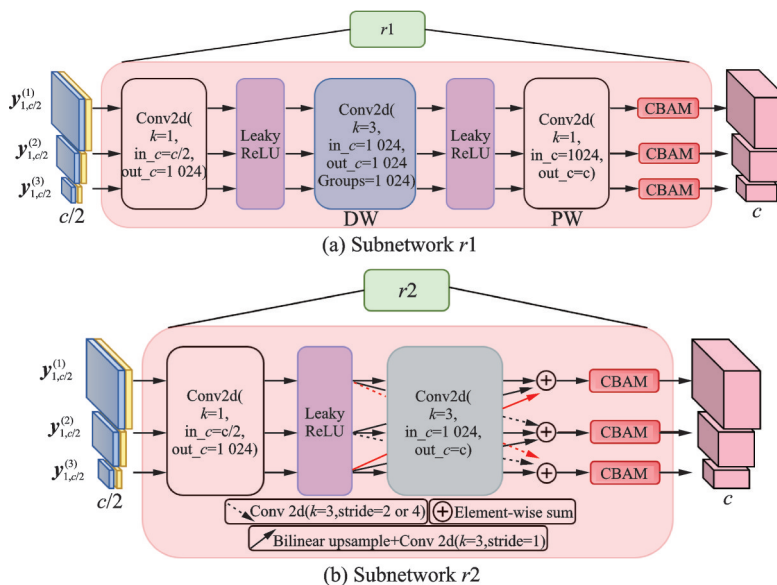


图2 ValidFlow内部子网络 $r1$ 、 $r2$ 结构图

Fig.2 Structure diagrams of ValidFlow internal subnetworks $r1$ and $r2$

3 实验结果及分析

3.1 实验设置

(1)数据集:为了验证本文方法的有效性和优越性,在MVTec AD^[31]、MTD磁砖数据集^[32]和DAGM数据集^[33]上评估其性能。

MVTec AD模仿了实际的工业生产场景,并且提供了像素级的标注,是一个包含多种物体和多种异常的数据集。该数据集一共有5354张图片,其中用于训练的缺陷图像3629张,用于测试的图像1725张,包含了10种对象类和5种纹理类。测试集包括裂纹、划伤和变形等不同尺寸、形状和类型的缺陷,每类缺陷类型最多可达8种,共70种缺陷类型,其详细缺陷类型如表1所示。

MTD提供了像素级的标注,包含5种缺陷:气孔、裂纹、磨损、断裂和不均匀,一共有1344张图像,其中缺陷图像392张,正常图像952张。本文将该数据集划分为训练集和测试集,其中训练集由4/5的正常图像构成,测试集则由1/5的正常图像和392张缺陷图像所构成。

DAGM是一个著名的表面缺陷检测的基准数据集,包含了人工合成的各种缺陷表面。该数据集一共有16100张图片,训练集和测试集各一半,其划分为10个图像类别,每个类别的缺陷图像与正常图像的比例为1:7。本文仅在训练集中的正常图像上进行训练。

(2)实施细节:由于本文所提的网络模型是在3个尺度上进行训练,对于MVTec AD和DAGM数据集,将图片尺寸缩放到 768×768 、 384×384 、 192×192 ,再将对应尺度的图片通过ImageNet上预训练的特征提取器进行特征抽离,获得了通道数为304,尺寸大小分别为 24×24 、 12×12 、 6×6 的特征图,并

表1 MVTec AD数据集15个类别的缺陷类型
Table 1 Defect types for 15 categories in MVTec AD dataset

种类	缺陷种类
网格	弯曲、破损、胶水污染、金属残留、线状物
皮革	颜色污染、划痕、折痕、胶水污染、戳痕
瓷砖	裂纹、胶粘条、灰色笔痕、油污、磨痕
地毯	颜色污染、划痕、裂口、金属残留、线状物
木材	颜色污染、混合损伤、戳痕、液体残留、划痕
瓶口	大面积破损、小面积破损、混合损伤
胶囊	破损、错误印记、戳痕、划痕、压痕
药片	颜色污染、混合损伤、杂物污染、裂痕、印记错误、类型错误、划痕
晶体管	引脚弯曲、引脚断裂、封装盒损伤、插口位置错误
拉链	链齿破损、混合损伤、织物边界损伤、织物内饰损伤、链齿磨损、链齿开口、链齿压痕
电缆	金属条弯曲、电缆组合错误、混合损伤、内部切伤、外部切伤、电缆缺失、金属条缺失、戳痕
榛子	裂口、划痕、戳痕、错误印记
螺母	弯曲、颜色污染、方向翻转、磨痕
螺钉	底部破损、头部划伤、颈部划伤、侧面螺纹损伤、正面螺纹损伤
牙刷	混合损伤

保存下来以构建3个尺度下的特征数据库;对于MTD数据集,由于原始图像尺寸过小,本文将缩放到 384×384 、 192×192 、 96×96 这3个尺度的图片,送入特征提取器后,抽取的特征图尺寸大小分别为 12×12 、 6×6 、 3×3 ,同样保存在外部以备训练使用。数据集的特征提取完成后,特征提取器在训练过程中保持固定。本文在Valid-Flow中使用 $n=3$ 个由可逆的FA flow和FB flow组合的模块。提供仿射变换参数的内部子网络 r_1 、 r_2 中的详细参数设置见图2所示,CBAM注意力机制模块详细结构参见文献[29]。在其余的设置中,使用Adam^[34]进行优化,学习率为 2×10^{-4} ,权重衰减为 10^{-5} ,batch size设置为16,并在MVTec AD数据集上训练了300轮,在MTD数据集上训练了60轮。用于测试的设备硬件配置为: Intel(R) Core(TM) i9-10900X CPU@3.70 GHz和NVIDIA GeForce RTX3080Ti。

(3)评价标准:采用图像级的受试者特征(Receiver operating characteristic, ROC)曲线和受试者特征曲线下的面积(Area under ROC, AUROC)。ROC曲线的特性是当测试集中正负样本分布发生变化时,ROC曲线保持不变。由于用于无监督方法的数据集大多存在严重的类不平衡现象,即正常图像的数量远超于缺陷图像,或者相反,故采用ROC曲线来直观地显示缺陷检测性能;AUROC是ROC曲线下的面积,该值是一个概率值,值越大,当前的分类算法越有可能将正样本排在负样本前,即越能够很好将图像分类,故选择AUROC来获得缺陷检测性能的精确定量评估。

3.2 对比实验

在3个流行的公开缺陷检测数据集上评估ValidFlow的性能,以验证所提方法相较于其他方法的优越性。

(1)MV Tec AD:表2展示了本文方法以及其他方法所达到的缺陷检测性能。本方法在15类中的平均AUROC为99.2%,超越了最高的竞争对手CS-Flow^[21]0.5%,并在11个类别中超过了所有的竞争对手,其中在羽毛、地毯、瓶口和榛子等4种类别中获得了100%的最佳AUROC性能。

(2)MTD:如表3所示,在MTD数据集上的AUROC达到了99.6%,超过了最高的竞争对手CS-Flow0.3%。从图3可以看到在该数据集上所有缺陷类别的ROC曲线和AUROC值,其中4种缺陷上AUROC均超过了99.6%,只有在磨损缺陷上(Fray)表现相对较差。图4中,横轴代表负的对数释然值(即 $\frac{1}{2} \mathbf{x}^2$),纵轴代表落在每个值域上的样本个数,故而能直观地发现本文方法能将缺陷图像映射到正

表2 各方法在MVTec AD数据集上所有类别的图像级AUROC对比结果

Table 2 Image-level AUROC comparison results of all categories of each method on MVTec AD dataset %

种类	ARNet ^[18]	Geom. ^[35]	GANomaly ^[14]	DSEBM ^[36]	Mahalanobis ^[26]	1-NN ^[37]	DifferNet ^[20]	CS-Flow ^[21]	ValidFlow
网格	88.3	61.9	70.8	71.7	93.7	81.8	84.0	99.0	99.5
皮革	86.2	84.1	84.2	41.6	100	100	97.1	100	100
瓷砖	73.5	41.7	79.4	69.0	100	100	99.4	100	99.9
地毯	70.6	43.7	69.9	41.3	99.6	98.5	92.9	100	100
木材	92.3	91.1	83.4	95.2	99.3	95.8	99.8	100	99.9
瓶口	94.1	74.4	89.2	81.8	99.0	99.6	99.0	99.8	100
胶囊	68.1	67.0	73.2	59.4	96.3	89.4	86.9	97.1	98.8
药片	78.6	63.0	74.3	80.6	91.4	79.9	88.8	98.6	98.3
晶体管	84.3	86.9	79.2	74.1	98.2	95.4	91.1	99.3	99.2
拉链	87.6	82.0	74.5	58.4	98.8	97.1	95.1	99.7	99.8
电缆	83.2	78.3	75.7	68.5	99.1	95.1	95.9	99.1	99.4
榛子	85.5	35.9	78.5	76.2	100	98.2	99.3	99.6	100
螺母	66.7	81.3	70.0	67.9	97.4	91.1	96.1	99.1	99.3
螺钉	100	50.0	74.6	99.9	94.5	91.4	96.3	97.6	98.5
牙刷	100	97.2	65.3	78.1	94.1	94.7	98.6	91.9	95.6
平均AUROC	83.9	67.2	76.2	70.9	97.5	93.9	94.7	98.7	99.2

常图像的分布之外,能够很好地区分缺陷样本和非缺陷样本,进而展现了本方法在图像缺陷检测领域上的优越性。

(3) DAGM: 如表4所示,其中有监督的方法在DAGM数据集上达到了完美的AUROC值,相反无监督的方法在该数据集上表现较差,然而本文方法和CS-Flow在没有进行任何数据扩增和参数调整的情况下实现了较好的性能,而本文方法ValidFlow则达到了99.0%的AUROC评分,在性能上已经非常接近有监督的方法,从而验证了本文方法具有较好的有效性和鲁棒性。




图3 MTD数据集上所有缺陷类别的ROC曲线
Fig.3 ROC curves for all defect categories on MTD dataset

表3 各方法在MTD数据集上的AUROC对比结果

Table 3 AUROC comparison results of each method on MTD dataset

方法	AUROC/%
Geom. ^[35]	75.5
GANomaly ^[14]	76.6
DSEBM ^[36]	57.2
Mahalanobis ^[26]	98.0
1-NN ^[37]	97.8
DifferNet ^[20]	97.7
PaDiM ^[27]	98.7
CS-Flow ^[21]	99.3
ValidFlow	99.6

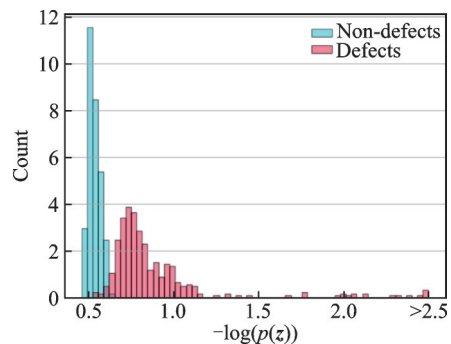


图4 MTD数据集上测试的负对数似然分布
Fig.4 Negative log-likelihood distributions tested on MTD dataset

表4 各方法在DAGM数据集上的AUROC对比结果

Table 4 AUROC comparison results of each method on DAGM dataset

%

种类	无监督					监督	
	skipGAN ^[38]	Puzzle AE ^[39]	CutPaste ^[40]	DifferNet ^[20]	CS-Flow ^[21]	ValidFlow	文献[41]
Class 1	58.3	50.7	56.1	59.7	94.0	94.3	100
Class 2	56.1	50.5	87.8	82.9	100	100	100
Class 3	55.1	58.7	57.1	69.8	97.1	96.2	100
Class 4	53.7	70.0	71.3	97.3	100	100	100
Class 5	57.4	63.6	47.4	61.2	100	100	99.9
Class 6	66.8	92.3	68.8	97.0	100	100	100
Class 7	52.4	54.0	96.5	68.5	99.5	99.4	100
Class 8	53.7	49.1	53.4	52.1	99.5	99.7	100
Class 9	52.3	54.6	51.9	78.2	99.6	99.9	100
Class 10	52.2	49.6	74.7	79.1	99.7	100	100
Average	55.8	59.3	66.0	74.6	98.9	99.0	100

3.3 模型复杂度分析

由于本文提出的方法是在CS-Flow上做出的改进,所以对其在参数量和推理速度参数每秒传输帧数(Frames per second, FPS)上进行对比。ValidFlow中FA flow或FB flow相当于CS-Flow中的一个耦合块,由于FA+FB模块的数量设置为3,为了公平地进行比较,CS-Flow中的耦合块数量设置为6,测试阶段batch size为16。在模型

参数量上,采用thop库去搜索网络,并自动计算;在推理时间上,为了精确计算出FPS,利用随机生成的虚假样例去对GPU进行预热,实验结果如表5所示。可以明显发现本文方法相比于CS-Flow,参数量减少了207.61M,推理速度FPS提升了22。这证明了在 r_1 模块中取消上下采样分支和引入深度可分离卷积的必要性,可以降低网络的训练负担,减少计算量,提升模型的推理速度,验证了本方法的有效性。

3.4 隐空间的特征可视化

由于本文方法在内部的子网络 r_1 和 r_2 上使用全卷积方式,在一定程度上保留了图像的位置信息,所以可以利用此特点进行缺陷的定位。图5每一列从上到下依次为正常图像、缺陷图像、缺陷图像的可视化图和缺陷图像及其可视化图的复合图,前3列为MVTec AD数据集的展示样例,随后3列为DAGM数据集的展示样例,最后1列为MTD数据集的展示样例。第3行展示了在第1个尺度下的输出 $z^{(1)}$ 沿通道维度进行平方值相加后,通过双线性插值方法放大到输入图像尺寸的可视化结果,可看出输出值的大小与异常区域有直接的联系。本文的网络是针对CS-Flow在图像级检测性能上的改进,并未在缺陷定位上进行优化,所以本文方法不提供精确的逐像素分割的缺陷定位性能,但从图5也能看出本方法在缺陷定位上具有一定潜力。

表5 两种方法在推理速度和参数量上的对比

Table 5 Comparison of two methods in inference speed and number of parameters

方法	参数/M	推理速度/FPS
CS-Flow	370.50	100
ValidFlow	162.89	122




图5 MVTec AD、DAGM 和 MTD 数据集的缺陷定位可视化图结果

Fig.5 Visualization result of defect location of MVTec AD, DAGM and MTD datasets

3.5 消融实验

为了研究 ValidFlow 中由可逆的 FA flow 和 FB flow 组合的模块数量的影响,在 MTD 数据集上进行了实验探究。如表 6 所示,当组合模块数量 $n=3$ 时, AUROC 达到最大,且继续提高组合模块的数量时, AUROC 略有下降,因此确定最佳组合模块数量为 3。

另一个实验中,在具有 15 类检测对象的 MVTec AD 数据集上探究了 FB flow 内部的子网络中引入 CBAM 注意力机制以及增加 1、3 尺度分支对于 ValidFlow 检测效果的影响。实验结果如表 7 所示,在 FB flow 中分别只添加两种结构中的一种,相较于两种都没有添加的网络,其 15 类检测对象的平均 AUROC 值都有小幅提升;当同时引入两种结构时, AUROC 值进一步提升,验证了在 ValidFlow 引入 CBAM 注意力机制以及增加 1、3 尺度分支的有效性和必要性。

4 结束语

本文提出了一种新的基于标准化流的无监督缺陷检测方法 ValidFlow,引入了两种耦合块 FA flow 和 FB flow。FA flow 中子网络 $r1$ 引入了深度可分离卷积,以此来减少参数量;FB flow 中子网络 $r2$ 则在保留原 CS-Flow 耦合块子网络设置的同时增加两条跨尺度分支,以达到充分混合信息的效果。采用特征平行流 FA flow 和特征混合流 FB flow 的设置不仅降低了参数数量,提高了推理速度,同时也充分利用了特征信息,并使得 ValidFlow 能够在 MVTec AD 和 MTD 数据集上获得最先进的性能。虽然本方法并未在缺陷定位上作出专门的优化,但在文中也发现了本方法在缺陷定位上获得了不错的效果,未来的工作将致力于探索基于标准化流的模型在缺陷定位上性能的提升。

表 6 在 MTD 数据集上不同组合模块数量的消融实验
Table 6 Ablation experiment of different number of combined modules on MTD dataset

n	1	2	3	4	5
AUROC/%	99.53	99.57	99.63	99.63	99.49

表 7 在 MVTec AD 数据集上 CBAM 注意力机制以及 1、3 尺度分支的消融实验

Table 7 Experiment on CBAM attention mechanism and ablation of scales 1 and 3 branches on MVTec AD dataset

CBAM ^[29]	1、3 尺度分支	AUROC/%
×	×	98.80
✓	×	98.97
×	✓	99.01
✓	✓	99.21

参考文献:

- [1] SHANG L, YANG Q, WANG J, et al. Detection of rail surface defects based on CNN image recognition and classification [C]//Proceedings of the 2018 20th International Conference on Advanced Communication Technology (ICACT). [S.l.]: [s.n.], 2018.
- [2] 胡佳美, 吴锡生. 一种新型的半导体 SMA 缺陷识别方法[J]. 数据采集与处理, 2019, 34(5): 923-932.
HU Jiamei, WU Xisheng. New method of semiconductor SMA defect recognition[J]. Journal of Data Acquisition and Processing, 2019, 34(5): 923-932.
- [3] 唐小煜, 熊浩良, 黄锐珊, 等. 基于改进的 U-Net 和 YOLOv5 的绝缘子掩模获取与缺陷检测[J]. 数据采集与处理, 2021, 36(5): 1041-1049.
TANG Xiaoyu, XIONG Haoliang, HUANG Ruishan, et al. Insulator mask acquisition and defect detection based on improved U Net and YOLOv5[J]. Journal of Data Acquisition and Processing, 2021, 36(5): 1041-1049.
- [4] 张芳慧, 章春娥, 张琳娜, 等. 基于多尺度重叠滑动池化的 SSD 果冻杂质检测方法[J]. 信号处理, 2020, 36(11): 1811-1818.
ZHANG Fanghui, ZHANG Chune, ZHANG Linna, et al. Jelly impurity detection based on scalable overlapping slide pooling SSD network[J]. Journal of Signal Processing, 2020, 36(11): 1811-1818.
- [5] 张琳娜, 岑翼刚. 铁轨图像的低秩矩阵分解缺陷检测[J]. 信号处理, 2019, 35(4): 667-675.
ZHANG Linna, CEN Yigang. Low-rank matrix decomposition for rail track image defect detection[J]. Journal of Signal Processing, 2019, 35(4): 667-675.
- [6] 钟克洪, 丁明跃, 周成平. 基于小波差分统计特征的纹理缺陷检测方法[J]. 系统工程与电子技术, 2004, 26(5): 660-664.
ZHONG Kehong, DING Mingyue, ZHOU Chengping. Texture defect inspection method using difference statistics feature in wavelet domain[J]. Journal of Systems Engineering and Electronics, 2004, 26(5): 660-664.
- [7] BOCHKOVSKIY A, WANG C Y, LIAO H. YOLOv4: Optimal speed and accuracy of object detection[EB/OL]. (2020-04-23). <https://doi.org/10.48550/arXiv.2004.10934>.
- [8] REDMON J, FARHADI A. YOLOv3: An incremental improvement[EB/OL]. (2018-04-08). <https://doi.org/10.48550/arXiv.1804.02767>.
- [9] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.
- [10] WANG C Y, YE H I H, LIAO H. You only learn one representation: Unified network for multiple tasks[EB/OL]. (2021-05-10). <https://doi.org/10.48550/arXiv.2105.04206>.
- [11] ZHU X, LYU S, WANG X, et al. TPH-YOLOv5: Improved YOLOv5 based on transformer prediction head for object detection on drone-captured scenarios[C]//Proceedings of International Conference on Computer Vision (ICCV) Workshops. [S.l.]: [s.n.], 2021.
- [12] RUFF L, KAUFFMANN J R, VANDERMEULEN R A, et al. A unifying review of deep and shallow anomaly detection [EB/OL]. (2020-09-24). <https://doi.org/10.48550/arXiv.2009.11732>.
- [13] 罗东亮, 蔡雨萱, 杨子豪, 等. 工业缺陷检测深度学习方法综述[J]. 中国科学:信息科学, 2022, 52(6): 1002-1039.
LUO Dongliang, CAI Yuxuan, YANG Zihao, et al. Survey on industrial defect detection with deep learning[J]. Scientia Sinica Informationis, 2022, 52(6): 1002-1039.
- [14] AKCAY S, ATAPOUR-ABARGHOU EI A, BRECKON T P. GANomaly: Semi-supervised anomaly detection via adversarial training[C]//Proceedings of the Asian Conference on Computer Vision. [S.l.]: [s.n.], 2018.
- [15] TSA B, PSA B, SMW B, et al. f-AnoGAN: Fast unsupervised anomaly detection with generative adversarial networks[J]. Medical Image Analysis, 2019, 56: 30-44.
- [16] CHONG Z, PAFFENROTH R C. Anomaly detection with robust deep autoencoders[C]//Proceedings of the the 23rd ACM SIGKDD International Conference. [S.l.]: ACM, 2017.

- [17] GONG D, LIU L, LE V, et al. Memorizing normality to detect anomaly: Memory-augmented deep autoencoder for unsupervised anomaly detection[C]//Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision (ICCV). [S.l.]: IEEE, 2020.
- [18] HUANG C, YE F, CAO J, et al. Attribute restoration framework for anomaly detection[EB/OL]. (2019-11-25). <https://doi.org/10.48550/arXiv.1911.10676>.
- [19] GUDOVSKIY D, ISHIZAKA S, KOZUKA K. CFLOW-AD: Real-time unsupervised anomaly detection with localization via conditional normalizing flows[C]//Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision. [S.l.]: IEEE, 2021: 98-107.
- [20] RUDOLPH M, WANDT B, ROSENHAHN B. Same same but DifferNet: Semi-supervised defect detection with normalizing flows[C]//Proceedings of the Workshop on Applications of Computer Vision(WACV). [S.l.]: [s.n.], 2021.
- [21] RUDOLPH M, WEHRBEIN T, ROSENHAHN B, et al. Fully convolutional cross-scale-flows for image-based defect detection[EB/OL].(2021-10-06). <https://doi.org/10.48550/arXiv.2110.02855>.
- [22] AN J, CHO S. Variational autoencoder based anomaly detection using reconstruction probability[EB/OL]. (2015-02-15). <https://dm.snu.ac.kr/static/docs/TR/SNUDM-TR-2015-03.pdf>.
- [23] YAN X D, ZHANG H D, XU X M, et al. Learning semantic context from normal samples for unsupervised anomaly detection [C]//Proceedings of the 35th AAAI Conference on Artificial Intelligence. [S.l.]: AAAI, 2021.
- [24] NAGATA F, TOKUNO K, NAKASHIMA K, et al. Fusion method of convolutional neural network and support vector machine for high accuracy anomaly detection[C]//Proceedings of the 2019 IEEE International Conference on Mechatronics and Automation (ICMA). [S.l.]: IEEE, 2019.
- [25] COHEN N, HOSHEN Y. Sub-image anomaly detection with deep pyramid correspondences[EB/OL]. (2020-05-05)[2021-03-15]. <https://arxiv.org/abs/2005.02357>.
- [26] RIPPEL O, MERTENS P, MERHOF D. Modeling the distribution of normal data in pre-trained deep features for anomaly detection[C]//Proceedings of the 25th International Conference on Pattern Recognition (ICPR). [S.l.]: IEEE, 2021: 6726-6733.
- [27] DEFARD T, SETKOV A, LOESCH A, et al. PaDiM: A patch distribution modeling framework for anomaly detection and localization[C]//Proceedings of International Conference on Pattern Recognition. [S.l.]: Springer, 2021: 475-489.
- [28] REZENDE D J, MOHAMED S. Variational inference with normalizing flows[C]//Proceedings of International Conference on Machine Learning. [S.l.]: PMLR, 2015: 1530-1538.
- [29] WOO S H, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]//Proceedings of the 15th European Conference on Computer Vision (ECCV). Munich, Germany:[s.n.], 2018.
- [30] CHOLLET F. Xception: Deep learning with depthwise separable convolutions[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) . [S.l.]: IEEE, 2017: 1800-1807.
- [31] BERGMANN P, FAUSER M, SATTLEGGER D, et al. MVTec AD—A comprehensive real-world dataset for unsupervised anomaly detection[C]//Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). [S.l.]: IEEE, 2020.
- [32] HUANG Y, QIU C, YUAN K. Surface defect saliency of magnetic tile[J]. *The Visual Computer*, 2018, 36(1): 1-12.
- [33] WIELER M, HAHN T. Weakly supervised learning for industrial optical inspection[C]//Proceedings of the Deutsche Arbeitsgemeinschaft für Mustererkennung (DAGM) symposium. [S.l.]: [s.n.], 2007.
- [34] KINGMA D, BA J. Adam: A method for stochastic optimization[EB/OL]. (2014-12-22). <https://doi.org/10.48550/arXiv.1412.6980>.
- [35] GOLAN I, RAN E Y. Deep anomaly detection using geometric transformations[C]//Proceedings of Advances in Neural Information Processing Systems. [S.l.]: [s.n.], 2018.
- [36] ZHAI S, YU C, LU W, et al. Deep structured energy based models for anomaly detection[EB/OL]. (2016-05-25). <https://doi.org/10.48550/arXiv.1605.07717>.

- [37] NAZARE T S, DE MELLO R F, PONTI M A. Are pre-trained CNNs good feature extractors for anomaly detection in surveillance videos[EB/OL]. (2018-11-20). <https://doi.org/10.48550/arXiv.1811.08495>.
- [38] AKAY S, ATAPOUR-ABARGHOUEI A, BRECKON T P. Skip-GANomaly: Skip connected and adversarially trained encoder-decoder anomaly detection[C]//Proceedings of the 2019 International Joint Conference on Neural Networks (IJCNN). [S.l.]: [s.n.], 2019.
- [39] SALEHI M, EFTEKHAR A, SADJADI N, et al. Puzzle-AE: Novelty detection in images through solving puzzles[EB/OL]. (2020-12-23). <https://doi.org/10.48550/arXiv.2008.12959>.
- [40] LI C L, SOHN K, YOON J, et al. CutPaste: Self-supervised learning for anomaly detection and localization[EB/OL]. (2021-04-08). <https://arxiv.org/abs/2104.04015>.
- [41] BOI J, TABERNIK D, SKOAJ D. End-to-end training of a two-stage neural network for defect detection[EB/OL]. (2020-07-15). <https://doi.org/10.48550/arXiv.2007.07676>.

作者简介:



张兰尧(1997-),男,硕士研究生,研究方向:机器视觉、深度学习、工业产品缺陷检测等,E-mail:zhanglanyao1@163.com。



陈晓玲(1976-),女,讲师,研究方向:机械设计、机器视觉。



张达敏(1967-),男,教授,博士生导师,研究方向:无线通信网络、网络优化等。



岑翼刚(1978-),男,教授,博士生导师,研究方向:低秩矩阵重构、稀疏表示、小波分析、异常检测。



张琳娜(1977-),通信作者,女,副教授,研究方向:工业产品缺陷检测、机器视觉,E-mail:zln770808@163.com。



黄彦森(1986-),男,高级工程师,研究方向:土木工程质量检测、计算机视觉。

(编辑:王静)