

基于神经网络的磁瓦表面缺陷检测识别

刘畅, 张剑, 林建平

(同济大学 机械与能源工程学院, 上海 201804)

摘要: **目的** 针对传统算法提取磁瓦表面缺陷的局限性, 以及通过人为选择缺陷特征进而判断缺陷种类的方法精度不足等问题, 结合改进的 UNet 模型和一个分类神经网络提出一种磁瓦缺陷检测识别算法。**方法** 改进的 UNet 模型用于提取缺陷, 而分类神经网络则用于对所提取的缺陷区域进行分类识别。为了提高模型的分类精度, 使用空洞卷积对 UNet 模型部分卷积层和池化层进行替代, 以减少多次池化带来的细节丢失的问题, 同时, 增加多次跳跃连接, 使 UNet 模型能够融合更多的卷积特征。**结果** 经实验验证表明, 改进 UNet 模型对缺陷区域的预测精度可达到 93%。根据预测结果使用分类神经网络对缺陷进行分类, 经实验验证, 分类的精度可达 94%, 满足工业要求。**结论** 改进的 UNet 模型对磁瓦缺陷提取精度有所提高, 分类神经网络的缺陷分类精度较高。结合改进的 UNet 模型和分类神经网络能同时并有效地实现缺陷提取和分类识别, 为磁瓦质量检测 and 性能评估打下基础。

关键词: 磁瓦; 表面缺陷; 缺陷提取; 缺陷分类识别; 图像分割; UNet

中图分类号: TP391.4 **文献标识码:** A **文章编号:** 1001-3660(2019)08-0330-10

DOI: 10.16490/j.cnki.issn.1001-3660.2019.08.044

Detection and Identification of Surface Defects of Magnetic Tile Based on Neural Network

LIU Chang, ZHANG Jian, LIN Jian-ping

(School of Mechanical and Energy Engineering, Tongji University, Shanghai 201804, China)

ABSTRACT: The work aims to propose a magnetic tile defect detection and recognition algorithm based on the improved UNet model and a classification neural network for the limitation of extracting the surface defects of the magnetic tile by the traditional algorithm, and the lack of accuracy in the method for judging the defect type by artificially selecting the defect feature. The improved UNet model was used to extract defects, and the classification neural network was used to classify and identify the extracted defect regions. In order to improve the classification accuracy of the model, the cavity convolution was adopted to replace the partial convolution layer and the pooling layer of the UNet model to reduce the loss of detail caused by multiple pooling. At the same time, adding multiple jump connections enabled the UNet model to combine more convolution features. The experimental results showed that the improved UNet model could predict the defect area by 93%. According to the prediction results, classification neural network was used to classify defects. After verified by experiment, the accuracy of the classification could reach 94% and meet the industrial requirements. The improved UNet model improves the accuracy of

收稿日期: 2018-12-25; 修订日期: 2019-02-21

Received: 2018-12-25; Revised: 2019-02-21

基金项目: 工信部 2017 年智能制造新模式项目

Fund: Ministry of Industry and Information Technology's 2017 Smart Manufacturing New Model Project

作者简介: 刘畅 (1995—), 男, 硕士研究生, 主要研究方向为计算机视觉。

Biography: LIU Chang (1995—), Male, Master, Research focus: computer vision.

通讯作者: 张剑 (1976—), 男, 博士, 副教授, 主要研究方向为计算机视觉和机器人学。邮箱: jianzh@tongji.edu.cn

Corresponding author: ZHANG Jian (1976—), Male, Doctor, Associated professor, Research focus: computer vision and robotics. E-mail: jianzh@tongji.edu.cn

magnetic tile defect extraction; the classified neural network has higher defect classification accuracy; and the combination of improved UNet model and classification neural network can realize the defect extraction and classification identification simultaneously and effectively, which lays a foundation for the quality detection and performance evaluation of the magnetic tile.

KEY WORDS: magnetic tile; surface defect; defect extraction; defect classification and recognition; image segmentation; UNet

作为永磁电机的核心组成部件，磁瓦在加工过程中易产生表面缺陷。磁瓦多纹理和弱对比度等特性，使其表面缺陷难以通过传统算法来检测。另外，通过人为选择缺陷特征，进而判断缺陷种类，具有一定的局限性。而卷积神经网络能够提取图像中不同维度的特征，大大消除噪声的干扰，能够很好地提取缺陷，并具有更高的缺陷分类精度。故本文研究基于神经网络的磁瓦表面缺陷提取和分类识别，对磁瓦表面质量检测 and 加工工艺参数的优化具有重要意义。

李雪琴等人^[1]提出一种非下采样 Contourlet 域自适应阈值面的磁瓦缺陷自动检测方法。林丽君等人^[2-3]提出一种基于图像加权信息熵和小波模极大值相结合的磁瓦表面裂纹缺陷检测算法，随后提出一种基于平稳小波包和非下采样方向滤波器组构造的轮廓波包变换的缺陷提取方法。杨成立等人^[4]提出了一种基于非下采样 Shearlet 变换的磁瓦表面缺陷检测方法。上述算法针对单一缺陷和简单背景的情况能够很好地解决问题，但由于磁瓦表面缺陷种类较多，不同种类缺陷颜色、形态均不尽相同，导致这些算法难以很好地提取每种缺陷。

国内外对基于神经网络的缺陷提取进行了相关研究。Park J K 等人^[5]提出了一种利用卷积神经网络 (CNN) 对零件表面的污垢、划痕、毛刺、磨损进行自动检查的方法。Gibert X 等人^[6]在一个多任务学习框架中组合多个检测器来提高检测铁道缺陷的能力。Cha Y J 等人^[7]利用卷积神经网络的深层架构来检测混凝土裂缝。Mei S 等人^[8]提出了一种无监督的基于学习的自动化方法来检测和定位织物缺陷，利用卷积

去噪自编码器网络在多个高斯金字塔层次上重构图像斑块。Duong B P 等人^[9]提出了一种采用深度神经网络结构的轴承组合故障检测新方法。Huang H W 等人^[10]提出了一种利用全卷积网络 (Full convolutional network, FCN) 提取的特征层次结构对地铁盾构隧道裂缝和渗漏缺陷进行语义分割的图像识别算法。综上所述，神经网络已广泛应用于缺陷检测领域，并取得了很好的效果，但目前表面缺陷的研究对象背景特征较为单一，而磁瓦具有多个表面且具有不同的形状，背景特征更加复杂。另外，在当下基于神经网络的缺陷提取算法中，通常仅对缺陷进行语义分割或只是单纯的分类识别，却并未同时实现这两个功能。

鉴于上述分析，针对磁瓦多个表面的多种缺陷，目前没有有效的检测算法以及分类识别算法，更不能同时实现磁瓦表面缺陷区域的提取和缺陷的分类识别。本文结合了两种神经网络，提出了一种磁瓦表面缺陷检测识别算法，同时实现了缺陷的提取和分类。

1 算法流程

算法流程整体分成两步进行：第一步，使用一个语义分割神经网络对磁瓦进行缺陷检测，提取缺陷区域；第二步，使用一个分类神经网络，根据磁瓦缺陷区域对其进行缺陷分类。具体算法步骤如下。

(1) 将待检测磁瓦原图缩小到 512×512 大小，并输入到语义分割神经网络，输出相应的缺陷区域预测图，如图 1a—c。

(2) 提取缺陷区域最小外接正方形，如图 1d 所示。

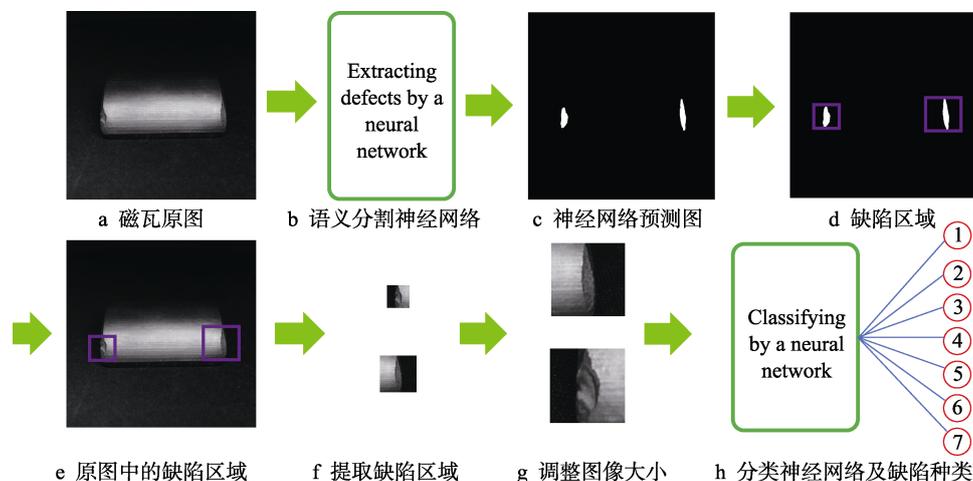


图 1 算法整体框架

Fig.1 Algorithmic framework: a) magnetic tile images; b) semantic segmentation neural network; c) neural network prediction map; d) defect region; e) defect region in the original image; f) defect extraction region; g) adjustment of image size; h) neural network for classification and defect type

(3) 根据最小外接正方形获取磁瓦原图局部缺陷图像, 如图 1e、f 所示。

(4) 将局部缺陷图像缩小到 64×64 像素, 并输入到分类神经网络进行缺陷分类, 如图 1g—h 所示。

1.1 缺陷区域提取

缺陷检测算法的第一个子任务是使用语义分割神经网络提取磁瓦表面缺陷区域。在进行缺陷区域提取前, 需对神经网络进行训练。

1.1.1 神经网络训练数据

选择 6 种不同类型的磁瓦作为样本, 如图 2 所示。

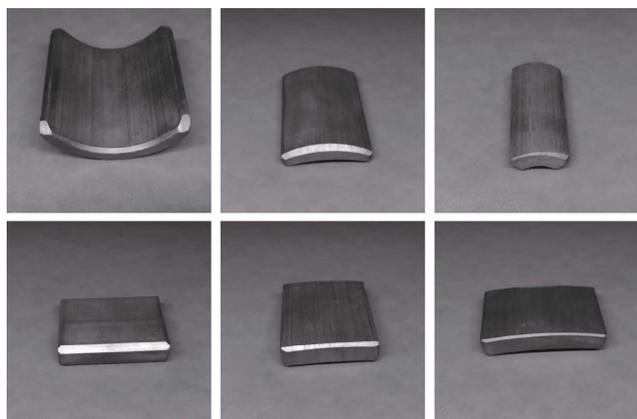


图 2 磁瓦种类
Fig.2 Types of magnetic tile

磁瓦表面缺陷多出现在上下表面和两个端面表面, 所以本文主要检测对象即为这四个表面。图 3 为神经网络输入图, 其中由于磁瓦上下表面为曲面, 使用一张拍摄图片会造成采光不均匀, 导致缺陷难以检测, 所以对上表面进行了四次拍摄, 如图 3a 所示, 对下表面进行两次拍摄, 如图 3b 所示, 两端面各使用一张图像显示, 如图 3c 所示。

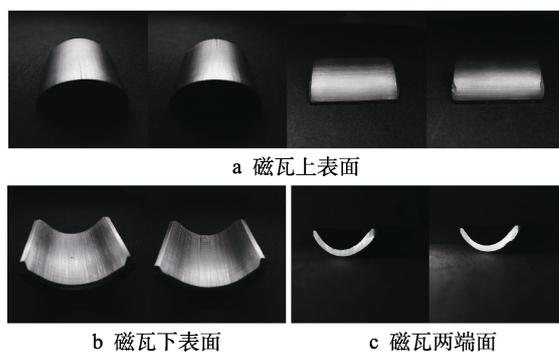


图 3 神经网络输入图像
Fig.3 Input image of neural network: (a) upper surface of the magnetic tile; (b) lower surface of the magnetic tile; (c) both sides of the magnetic tile

考虑到全卷积神经网络训练是有监督的学习过程, 因此需要输入图像对应的标签数据。本文通过人工方式提取图片中的缺陷区域, 进行标注后作为标签, 如图 4b 所示。

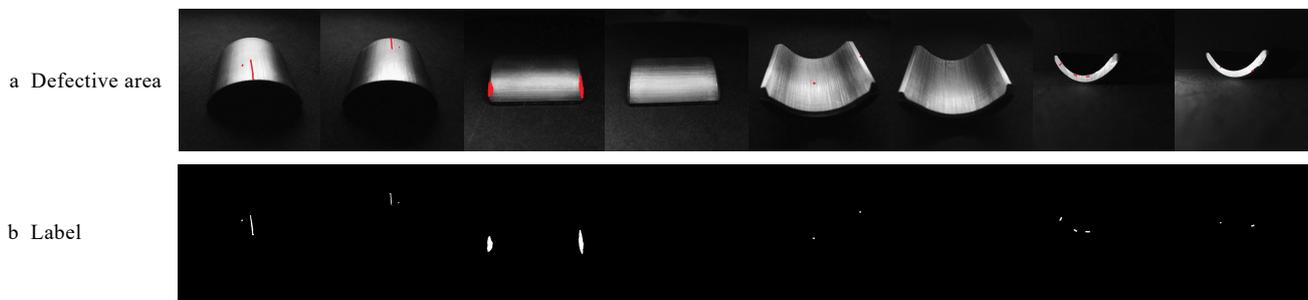


图 4 人工标注磁瓦缺陷区域
Fig.4 Magnetic tile defect area labeled manually

本文选取 1288 张分辨率大小为 2048×2048 的图像作为训练数据集, 200 张作为验证数据集, 最后 200 张作为测试数据集, 用于对算法性能进行测试。图像下采样到 512×512 分辨率大小, 并输入到神经网络。经多次实验分析发现, 下采样操作对缺陷检测精度的影响较小, 但大大减小训练和检测时间, 并根据磁瓦工业检测标准, 个别过小的缺陷可以忽略。另外, 为了保证分类精度, 各种类型缺陷磁瓦的数量近似相等 (包括无缺陷磁瓦)。为了丰富训练数据集, 本文对图像进行旋转、平移、上下左右翻转、缩放等数据增强操作, 变相扩充了数据类型, 能够提高神经网络的泛化能力。

1.1.2 UNet 模型的改进

UNet 模型^[1]能够充分利用训练图片数据, 在训练数据集较少的情况下依然表现良好, 非常适合目前磁瓦图片数量不多的情况。另外, UNet 模型常用于少类别分类, 比如二分类、三分类的情况^[12], 而本文的磁瓦表面缺陷提取属于二分类, 因此选择基于 UNet 模型提取磁瓦表面缺陷。

对于 UNet 模型 (如图 5), 在编码器中, 随着卷积和最大池化操作, 导致细节丢失, 因此对 UNet 模型进行两处改进: 使用空洞卷积代替编码器中部分卷积层和池化层, 如图 5 红色虚线框所示; 增加多次跳跃连接操作, 如图 6 红色虚线框所示。图 5、6 中的

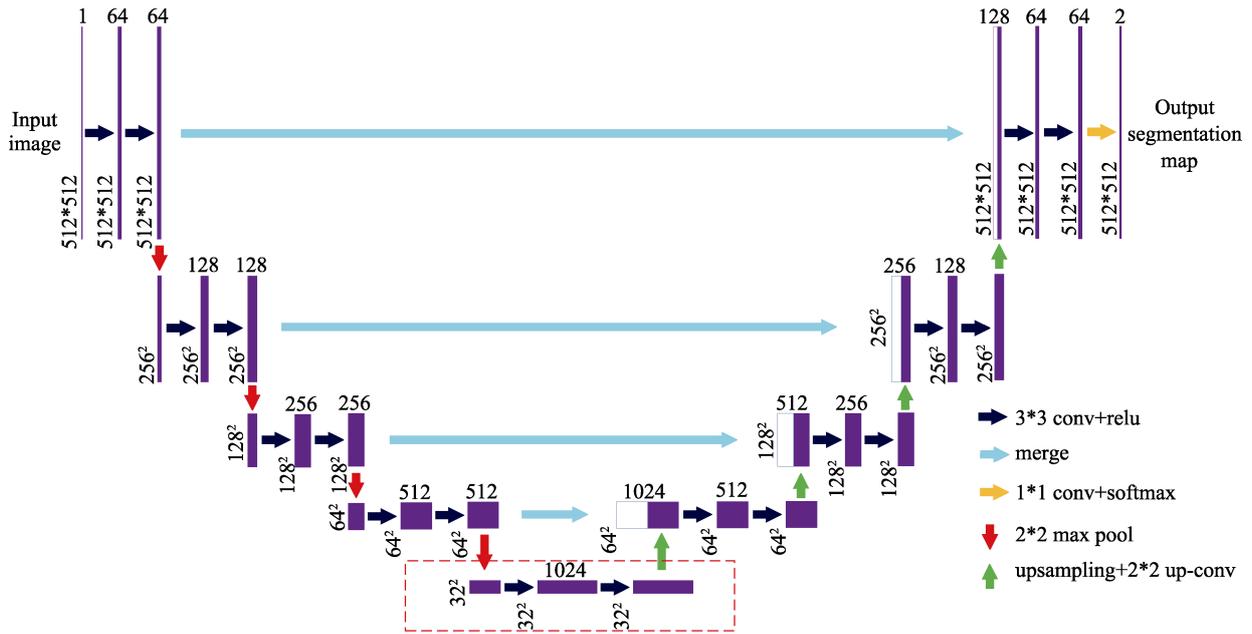


图 5 UNet 模型
Fig.5 UNet model

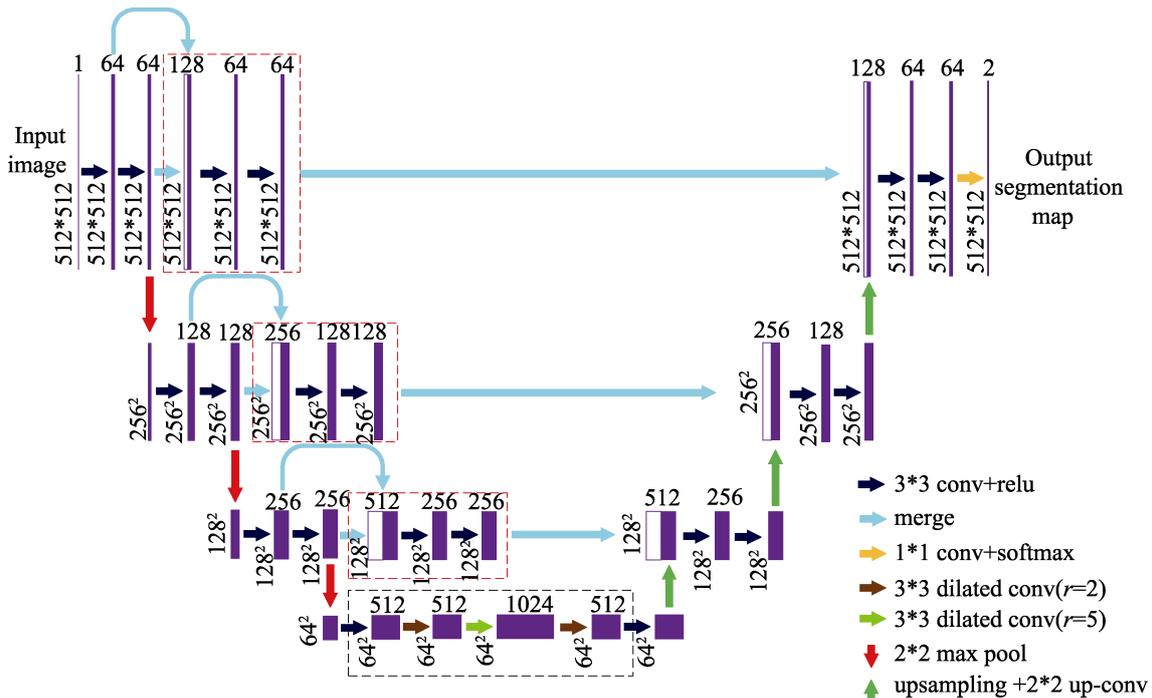


图 6 改进后模型
Fig.6 Improved model

数字表示各层维度大小。改进的 UNet 模型总训练参数为 14 740 226。

其中，针对这两处改动，具体细节如下所述：

1) 使用空洞卷积。UNet 模型中过多的池化操作会导致图像细节信息丢失。而空洞卷积不需要池化操作，同时在计算量相当的情况下，增大膨胀系数 r 来增大感受野大小，保持原有图像分辨率^[13]。但是，如果连续进行相同膨胀系数的空洞卷积操作，卷积采样会非常稀疏，将导致局部信息不完整和远距离信息不

相关^[14]。因此本文根据论文[14]提出的 HDC 算法，使用膨胀系数 r 分别为 1、2、5 等连续空洞卷积代替 UNet 模型中部分卷积层和池化层(图 6 黑色虚线框)。改进后卷积层编码器中最大感受野为 212×212 ，相比原 UNet 模型感受野 140×140 更大，能够获取更多信息。

2) 增加多次跳跃连接。在原 UNet 模型的解码器中，模型只使用了最大池化操作前的卷积层，而忽略了中间卷积层，并没有充分利用其包含的细节信息。而所有卷积层信息对于许多视觉任务都是非常有效

的^[15],那么更加充分地利用神经网络卷积层信息来提高性能是一个很好的选择^[16]。为此,相对于原本的UNet模型,本文改进的UNet模型增加多次跳跃连接,从而利用更多的中间卷积层信息,如图6中红色虚线框所示,这些卷积层的信息逐步融合到解码器中。因此,虽然在多次最大池化操作过程中大量细节不断丢失,但是通过多次跳跃连接操作,依然可以使高维特征与低维特征很好地结合,有助于最终缺陷的提取,后续实验对此进行了验证。

3)训练改进的UNet模型。为了确定神经网络训练参数,需对其进行训练。神经网络由感知机堆叠而成,而每个感知机由多个感知器组合而成。每个感知器的输出是输入信号的加权和,每一个输入信号*i*都有特定的权重 W_i ,所有的权重参数共同构成神经网络的训练参数 W ,而神经网络训练过程的本质就是求解训练参数 W ,使得神经网络达到拟合训练数据集的最优状态。另外,可以使用损失函数对这种拟合程度进行评价。损失函数是对神经网络输出值与真实标签之间的距离度量,反映两者之间的差值。

综上所述,损失函数是以参数 W 为自变量组合而成的复合函数,神经网络的训练过程就是基于训练数据集(包括训练图像*x*和对应标签*y*),以损失函数最小为目标,对网络权重参数 W 进行求解。权重参数 W 的求解公式如式(1)所示,其中, n 为一次参加训练的图像像素点个数, $\{x_i, y_i\}$ 为相应像素点*i*的训练数据, L 为损失函数。

$$W = \arg \min \sum_{i=0}^n L(\{x_i, y_i\}; W) \quad (1)$$

对于损失函数的求解方法,目前多使用梯度下降法进行计算,计算流程如下:①随机初始化所有参数 W ,并计算对应的损失函数;②计算损失函数相对于训练参数的偏导数(梯度大小);③沿梯度反向,以一定步长(学习率)更新训练参数(梯度反向是损失函数下降最快的方向),使得损失函数往最小值的方向变化;④不断迭代上述步骤,指导损失函数达到某一极小值或一定的迭代次数,结束计算。其中,有两个值得注意的地方:一是梯度下降法,梯度下降法需要在全部训练数据上最小化损失函数,导致计算量较大,而实际应用中一般采用批量梯度下降法,每次只计算一部分训练数据的损失函数,这一部分数据成为一个batch,大大提高训练速度,并且训练结果与梯度下降法很接近;二是学习率的选择,过小的学习率会导致函数收敛速度变慢,且易陷入局部极小值点,过大的学习率可能导致参数在函数最小值的两次震荡,甚至发散,无法获取全局最小值点。根据上文所述,训练神经网络过程中,需要合理选择损失函数、学习率 η 以及梯度下降算法。

对于损失函数,由于交叉熵损失函数能够很好地保证训练速度,所以本文选择交叉熵损失函数作为神

经网络的损失函数,定义如下:

$$L(\{x_i, y_i\}; W) = - \sum_{j=0}^1 y_i^j \log P(y_i^j = 1 | x_i; W) \quad (2)$$

$$P(y_i^j = 1 | x_i; W) = \frac{e^{Y^j(x_i)}}{\sum_{k=0}^K e^{Y^k(x_i)}} \quad (3)$$

式中: $Y^j(x_i)$ 为像素点 x_i 的*j*类预测值; K 为类别总数; P 为预测值所属*j*类的概率。

图像中缺陷区域为正样本,其余为负样本。然而由于图像中大部分区域为背景区域,负样本数量较大,导致数据不平衡较严重。为了弥补正负样本比例失衡,在模型中对损失函数进行了修改,为正、负样本分别设置不同的权重,增加参数 λ_j 修正正负样本损失权重,修改公式如下:

$$L(\{x_i, y_i\}; W) = - \sum_{j=0}^1 \lambda_j y_i^j \log P(y_i^j = 1 | x_i; W) \quad (4)$$

其中, λ_j 是通过计算多张图像中的正负样本比例的平均值来确定,本文设置为307,并在训练过程中保持值不变。

对于学习率 η ,初始学习率设置为0.0001,选择Adam优化器进行迭代优化。对于梯度下降算法,选择小批量随机梯度下降算法,批大小batchsize设为4,epoch设置为500。另外,为了避免训练过拟合,在训练过程中使用提前终止正则化手段。

为了对模型进行可靠的评估,使用5折交叉验证来验证本文模型。将训练集和验证集总体平均分为5个分区,将模型在其中4个分区上进行训练,并在剩余一个分区上进行评估。模型的验证分数等于5个验证分数的平均值。经过训练,计算每个轮次中5个验证分数的平均值以及5个训练分数的平均值,可得到训练损失和验证损失,如图7所示。可以看出,验证损失在约350轮后不再显著降低,之后开始过拟合。通过提前终止正则化手段,可以获取交叉熵损失约为0.3的模型参数。部分磁瓦缺陷提取结果如图8所示,可见神经网络预测的缺陷区域与缺陷标签的重合度较高。

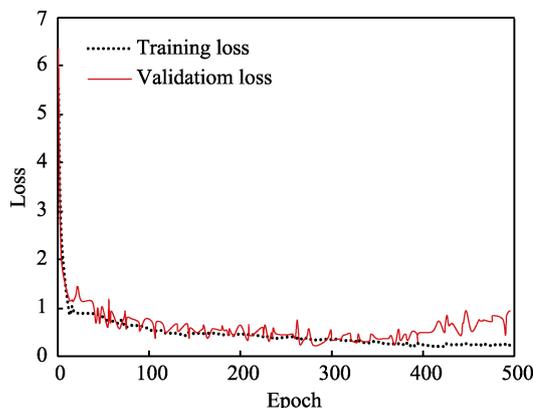
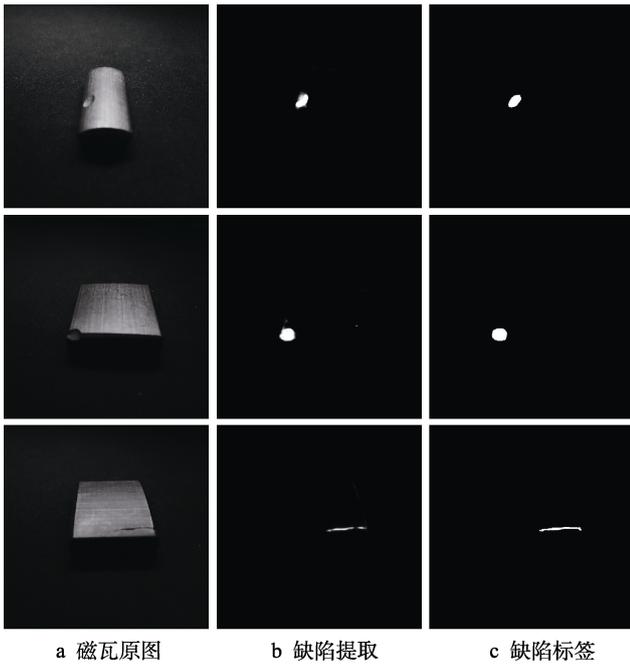


图7 训练损失和验证损失
Fig.7 Training and validation loss



a 磁瓦原图 b 缺陷提取 c 缺陷标签

图 8 磁瓦缺陷提取

Fig.8 Magnetic tile defect extraction: (a) magnetic tile image; (b) defect extraction; (c) defect label

1.2 缺陷种类识别

根据改进 UNet 模型获取磁瓦表面缺陷区域后，需进一步对磁瓦缺陷进行分类。本文构建一个分类神经网络对缺陷进行分类。

1.2.1 分类神经网络训练数据

磁瓦表面缺陷有多种类型，本文对其中 6 种主要缺陷类型进行识别，分别为凹坑、掉角、裂纹、漏磨、水裂和削角，如图 9 所示。对磁瓦原图中的缺陷区域进行裁剪，作为分类神经网络的输入图像。另外，为了弥补改进的 UNet 模型缺陷区域检测中可能发生的错误，即把非缺陷区域误判为缺陷区域进行了提取，在分类神经网络的输入图像类别中增添无缺陷类，截取磁瓦图像中的非缺陷区域作为该类的输入图像。综上所述，分类神经网络的标签种类为 7 种，所有标签进行 One-hot 编码处理。

数据集中的缺陷图像数量一共有 1931 张缺陷图像，图像像素大小是根据缺陷形状大小进行截取的，

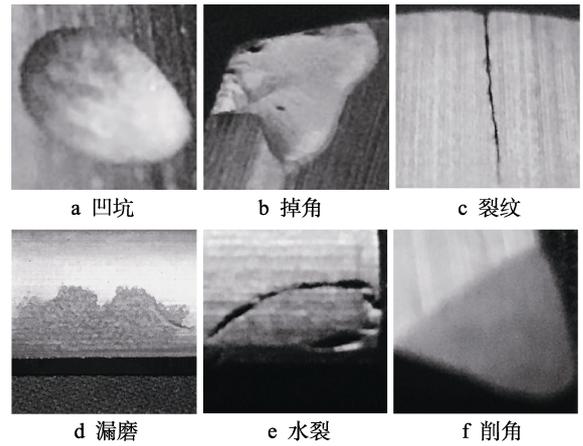


图 9 磁瓦缺陷种类

Fig.9 Types of magnetic tile defects: (a) pit; (b) notch; (c) crack; (d) grinding; (e) water crack; (f) chamfer

所以不尽相同。其中，选取 1200 张作为训练数据集，331 张作为验证数据集，最后 400 张作为测试数据集。数据集中的不同缺陷种类磁瓦数量保持近似相等（包括无缺陷类）。为了丰富训练数据集，在缺陷分类过程中，本文依然对输入图像使用旋转、平移等操作进行数据增强。

1.2.2 分类神经网络结构

为了更好地进行缺陷分类，本文构建了一个分类神经网络，如图 10 所示，图中数字表示特征图维度，其结构为：输入层接收分辨率大小为 64×64 的图像，通过反复堆叠卷积层和最大池化层的结构，对图像特征信息进行提取。其中，使用卷积核大小为 3×3 的卷积层和池化窗口为 2×2 的最大池化层，每层卷积层后使用激活函数 Relu 进行非线性处理。通过不断的卷积操作，不断扩大卷积层感受野，获取更大区域的特征信息，特征图通道数越来越深，并对这些特征信息进行采集融合，直到形成大小为 4×4 、通道数为 256 的特征图，再使用两层全连接层将特征图映射到类别空间中，第一层中使用 dropout 来避免过拟合，dropout 比率设为 0.5。最后类别空间的种类个数根据类别数量来确定。网络中的参数总数为 2 489 095。

1.2.3 分类神经网络训练

使用改进 UNet 模型中改进后的交叉熵损失函数

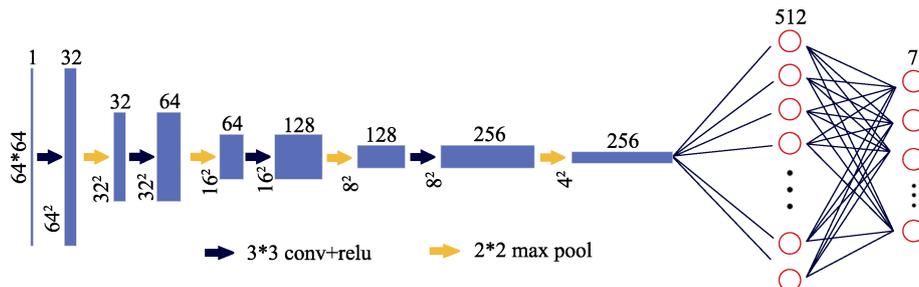


图 10 分类神经网络

Fig.10 Neural network for classification

作为分类神经网络的损失函数,区别在于其输出种类个数设置为7种(加上无缺陷类),而不是语义分割中的两类。epoch设置为100,批大小(batchsize)为6,初始学习率设置为0.0001,选择Adam优化器进行迭代优化。训练过程中的分类精度变化曲线和损失函数变化曲线如图11—12所示,可以看出模型在约80轮后不再显著降低,之后开始过拟合。通过提前终止正则化手段,可以获取缺陷分类精度约为98.3%以及交叉熵损失约为0.13的模型。

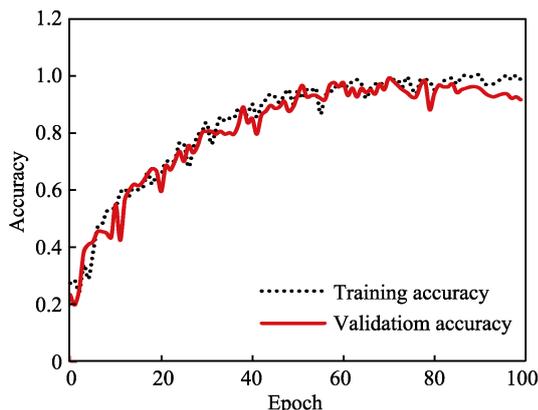


图11 训练精度和验证精度

Fig.11 Training and validation accuracy

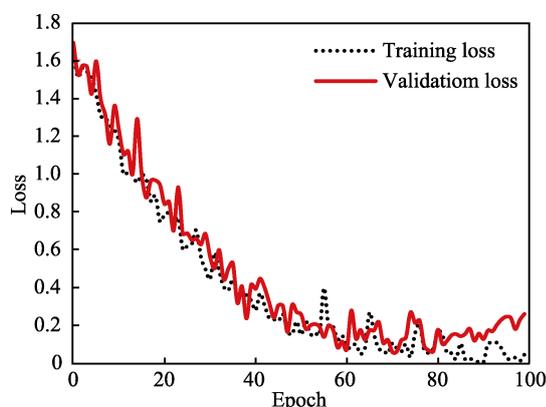


图12 训练损失和验证损失

Fig.12 Training and validation loss

2 实验与分析

2.1 算法评价指标

神经网络预测的缺陷可分为四组:真阳性点、假阳性点、真阴性点和假阴性点。真阳性表示缺陷被正确检测,假阳性表示无缺陷被误检为缺陷,真阴性点表示无缺陷被正确检测,假阴性点表示缺陷被误检为无缺陷。

为了评价神经网络缺陷提取能力,使用正确率(Accuracy)、灵敏度(Sensitivity)和特异度(Specificity)^[17]作为模型分类性能评价标准。正确率是指分类正确的样本数与所有样本数之间的比例。

灵敏度是所有正样本中正确分类的样本比例。特异度是指所有负样本中正确分类的样本比例。计算公式如式(5)~(6)所示,其中,TP为真阳性点的个数,TN为真阴性点的个数,P为所有正样本的个数,N为所有负样本的个数,FN为假阴性点的个数。根据神经网络预测图 and 对应标签可计算得到TP、TN、P、N、FN等参数值。

$$\text{Accuracy} = \frac{TP + TN}{P + N} \quad (5)$$

$$\text{Sensitivity} = \frac{TP}{TP + FN} \quad (6)$$

$$\text{Specificity} = \frac{TN}{TP + FN} \quad (7)$$

2.2 实验结果与分析

由于本文主要针对磁瓦缺陷分类进行研究,为了更好地对本文算法进行评价,需要与其他算法进行对比实验。由于目前很少有算法能够同时实现缺陷的提取和分类,所以本文对缺陷区域提取和缺陷分类进行分别对比。对于缺陷提取,选择UNet算法和文献[4]算法与本文算法进行对比。对于缺陷分类,选择滑动窗口缺陷检测算法^[82]和文献[18]算法与本文算法进行对比(文献[18]算法没有磁瓦缺陷区域提取步骤,直接使用本文算法中的磁瓦表面缺陷提取结果)。其中,滑动窗口缺陷检测算法是通过使用特定大小的检测窗口在图像上移动,将窗口内的局部图像输入神经网络进行缺陷检测,最终完成对整张图像的检测,目前在缺陷检测领域有广泛的应用。本文使用1000张实验图像进行算法验证,由于磁瓦表面可能出现多种缺陷,所以总的表面缺陷数量为1269个,其中凹坑为201个,掉角为178个,裂纹为187个,漏磨为181个,水裂为166个,削角为176个,无缺陷为180(一个无缺陷磁瓦算一个无缺陷种类)。对于缺陷提取,实验对比结果如图13所示。

从图13可以直观地看出,UNet模型会将一些非缺陷区域预测为缺陷区域,而文献[4]算法会将部分磨削纹理误检为缺陷区域,且对部分缺陷区域提取不完整。这是由于传统算法多根据特定的特征结构对相应的缺陷进行提取,而本文磁瓦表面缺陷种类较多,背景较为复杂,难以根据一个或几个特定特征结构进行提取,并且传统算法只针对图像局部区域进行检测,很可能将磨削纹理误检为缺陷。再根据公式(5)~(7)计算神经网络缺陷预测图的正确率、灵敏度和特异度,并绘制箱体图,如图14所示。

从图14可以看出,改进UNet模型的灵敏度明显好于UNet模型和文献[4]算法,这是由于改进UNet模型中的空洞卷积和更多的跳跃连接使得感受野更大,以及在解码层中吸收了更多的细节信息,提高了最终的检测精度。另外,三种算法的正确率和特异度都比较大,这是由于图像中负样本数量远大于正样本

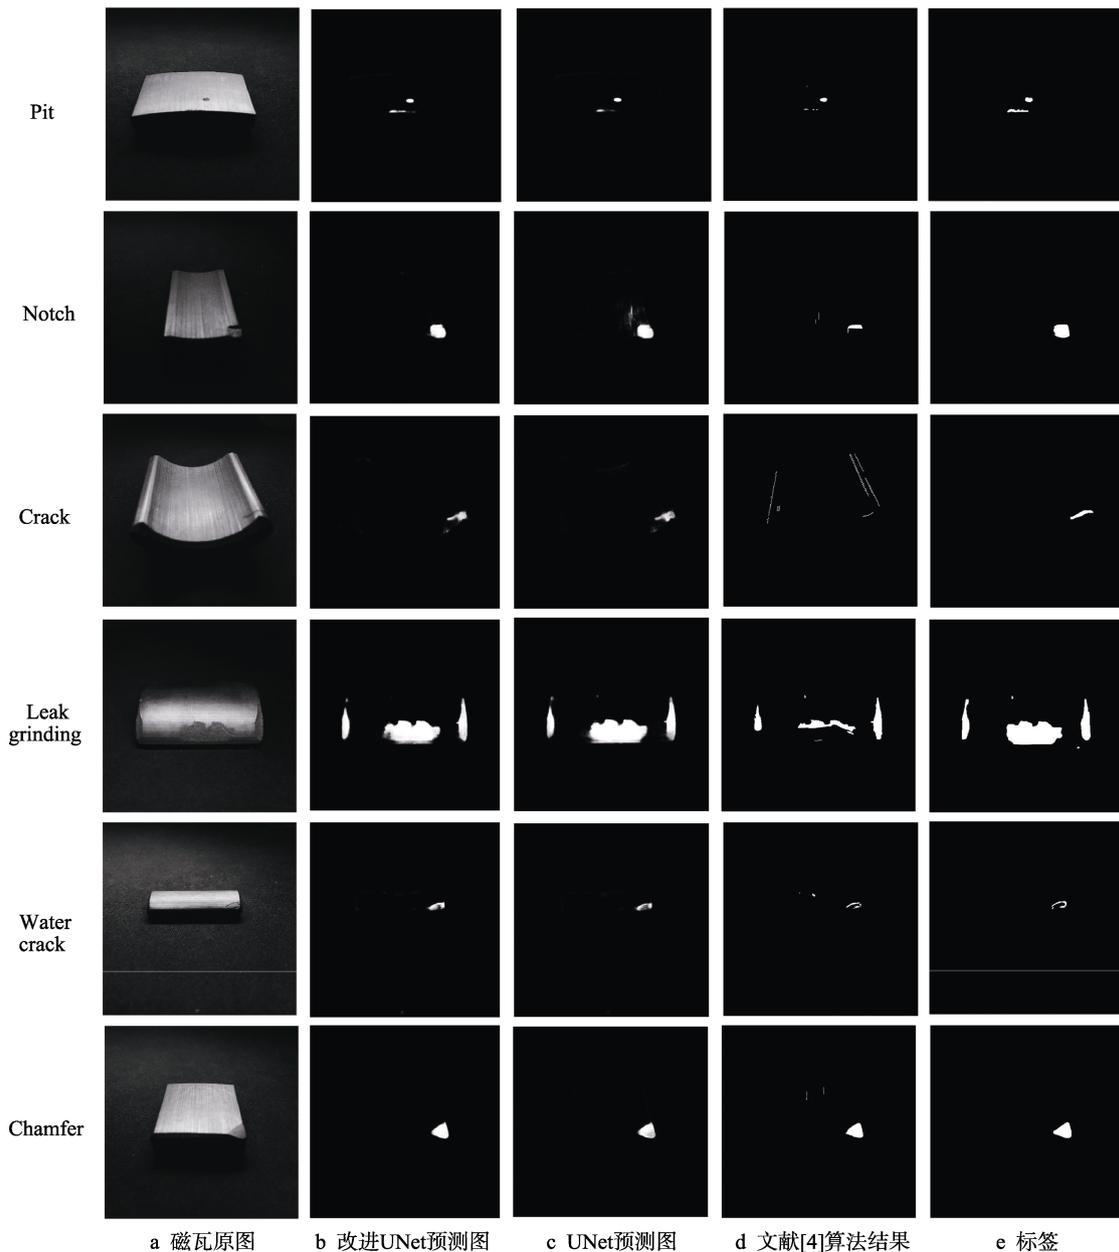


图 13 缺陷预测图

Fig.13 Defect prediction chart: (a) magnetic tile; (b) prediction for improved UNet; (c) prediction for UNet; (d) prediction for algorithm in reference [4]; (e) label

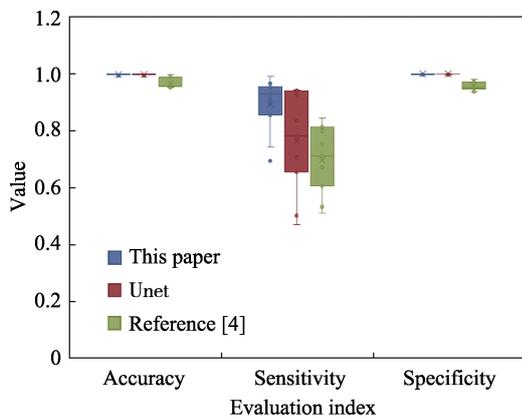


图 14 正确率、灵敏度和特异度
Fig.14 Accuracy, sensitivity and specificity

数量所致。其中各评价指标具体数值如表 1 所示，改进的 UNet 模型的灵敏度能够达到平均 93% 的像素级精度，表明 93% 的缺陷区域被正确预测。

缺陷分类结果如表 2 所示，可以看出，掉角和削角、裂纹和水裂之间的检错率相对较高，这是由于掉角和削角、裂纹和水裂的缺陷特征具有较高的相似度。另外，根据公式 (5) 可计算出本文算法的准确率为 94%，并根据公式 (6) 可计算出各缺陷种类的分类灵敏度，以表明每种缺陷正确分类的比例，如图 15 所示。

由图 15 可知，相对于其他两种算法，本文算法对各种缺陷均具有较高的分类精度，均达到 92% 以上，而且将无缺陷误检为缺陷的概率很小，仅为

表 1 模型结果对比
Tab.1 Comparison of simulation results

| Algorithm | Accuracy/% | | | Sensitivity/% | | | Specificity/% | | |
|---------------|------------|--------|------|---------------|--------|------|---------------|--------|------|
| | Mean | Median | Std | Mean | Median | Std | Mean | Median | Std |
| This paper | 0.99 | 0.99 | 0.01 | 0.93 | 0.91 | 0.05 | 1.0 | 1.0 | 0 |
| UNet | 0.99 | 0.99 | 0.01 | 0.78 | 0.82 | 0.13 | 1.0 | 1.0 | 0 |
| Reference [4] | 0.97 | 0.95 | 0.02 | 0.69 | 0.71 | 0.11 | 0.96 | 0.96 | 0.02 |

表 2 缺陷分类结果
Tab.2 Results of defect classification

| Predicted class | | Actual class | | | | | | | |
|-----------------|---|--------------|-------|-------|---------------|-------------|---------|-----------|--|
| | | Pit | Notch | Crack | Leak grinding | Water crack | Chamfer | Qualified | |
| Pit | A | 187 | 5 | 0 | 0 | 0 | 3 | 4 | |
| | B | 180 | 9 | 0 | 0 | 0 | 2 | 4 | |
| | C | 165 | 15 | 0 | 0 | 3 | 6 | 6 | |
| Notch | A | 2 | 165 | 0 | 0 | 0 | 9 | 0 | |
| | B | 8 | 157 | 0 | 4 | 0 | 11 | 0 | |
| | C | 15 | 149 | 0 | 10 | 0 | 15 | 0 | |
| Crack | A | 0 | 0 | 180 | 0 | 11 | 0 | 0 | |
| | B | 0 | 0 | 180 | 0 | 11 | 0 | 0 | |
| | C | 0 | 0 | 175 | 0 | 20 | 0 | 0 | |
| Leak grinding | A | 9 | 0 | 0 | 169 | 0 | 0 | 3 | |
| | B | 13 | 0 | 0 | 165 | 0 | 3 | 6 | |
| | C | 11 | 0 | 0 | 144 | 0 | 0 | 6 | |
| Water crack | A | 0 | 0 | 7 | 0 | 155 | 0 | 0 | |
| | B | 0 | 0 | 7 | 0 | 155 | 0 | 0 | |
| | C | 0 | 0 | 10 | 0 | 143 | 0 | 0 | |
| Chamfer | A | 3 | 8 | 0 | 10 | 0 | 164 | 0 | |
| | B | 0 | 12 | 0 | 10 | 0 | 158 | 0 | |
| | C | 5 | 14 | 0 | 16 | 0 | 147 | 5 | |
| Qualified | A | 0 | 0 | 0 | 2 | 0 | 0 | 173 | |
| | B | 0 | 0 | 0 | 2 | 0 | 2 | 170 | |
| | C | 5 | 0 | 2 | 11 | 0 | 8 | 163 | |

Appendix: A—This paper, B—Sliding window defect detection algorithm, C—Reference[18]; the number 5 in the first line indicates that algorithm A misdetected 5 Notch defective magnetic tiles as Pit defective magnetic tiles, others can deduce the rest from this.

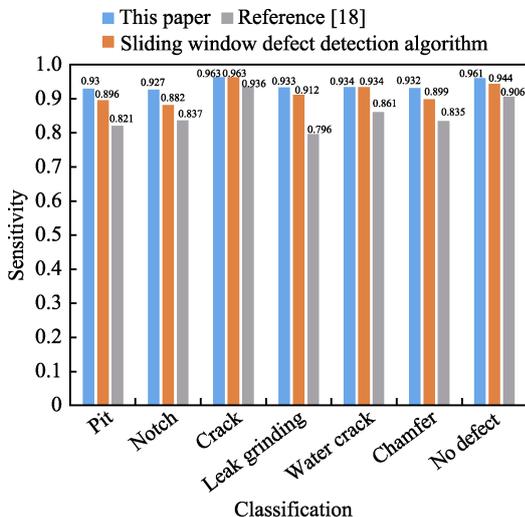


图 15 灵敏度评价指标
Fig.15 Sensitivity evaluation index

3.9%，反映本文算法对每个缺陷具有较高的分类精度。对单个磁瓦的检测时间对比如表 3 所示，由于传统算法检测过程中计算量较小，导致本文算法的检测时间相对于文献[18]较长，但满足工业要求。

滑动窗口缺陷检测算法中的神经网络训练过程复杂度较小（只需一次神经网络训练），但对缺陷分类的效果最差，这是由于磁瓦表面缺陷的大小不尽相同，而滑动窗口缺陷检测算法使用一定大小的窗口在磁瓦图像上进行滑动检测，如果缺陷区域过大，则不

表 3 检测时间对比
Tab.3 Comparison of detection time

| Algorithm | Detection time/s |
|---|------------------|
| This paper | 0.787 |
| Sliding window defect detection algorithm | 0.899 |
| Reference [18] | 0.672 |

能完全显示在一个窗口中。如果将滑动窗口设置较大,虽然能够包含所有缺陷,但会带来两个问题:①导致缺陷检测精度明显下降,较大的窗口会带来更多的背景干扰;②如果滑动窗口同时包含两种缺陷,导致缺陷分类不准确。文献[18]中的分类算法是通过人为选择缺陷特征来进行分类,如不变矩特征、像素点灰度平均值和灰度方差值作为缺陷特征量,不需要训练过程,但具有一定的局限性,而神经网络是通过自动选择合适的特征进行分类,具有更高的泛化性,能够实现较高的分类精度。

综上所述,本文算法不仅能提取较高精度的缺陷区域,而且同时能够实现较高缺陷分类精度。

3 结论

针对传统图像缺陷检测算法由于磁瓦多纹理和弱对比度等特性导致缺陷难以检测的难题,以及根据人工选择的缺陷特征对其进行分类时精度较差的困境,本文提出了一种结合表面缺陷区域提取和缺陷分类的算法。对 UNet 模型进行各卷积层分析后,进行以下改进:①使用空洞卷积代替部分卷积层和池化层,避免过多的细节丢失;②通过多次跳跃连接使解码器能够融合更多的卷积特性。使用优化后的 UNet 模型进行缺陷提取,能正确预测出 93% 的缺陷区域。然后,根据预测结果对磁瓦原图缺陷区域截取,并使用一种分类神经网络对截取的缺陷特征进行分类,经实验验证,本文算法能够同时实现 93% 的缺陷区域提取灵敏度和 94% 的缺陷分类精度,满足工业要求。

参考文献:

- [1] 李雪琴, 蒋红海, 刘培勇, 等. 非下采样 Contourlet 域自适应阈值的磁瓦表面缺陷检测[J]. 计算机辅助设计与图形学学报, 2014, 26(4): 553-558.
LI Xue-qin, JIANG Hong-hai, LIU Pei-yong, et al. Defect detection on magnetic tile surface based on adaptive threshold surfaces in NSCT domain[J]. Journal of computer-aided design & computer graphics, 2014, 26(4): 553-558.
- [2] 林丽君, 殷鹰, 何明格, 等. 基于小波模极大值的磁瓦裂纹缺陷边缘检测算法[J]. 电子科技大学学报, 2015, 44(2): 283-288.
LIN Li-jun, YIN Ying, HE Ming-ge, et al. Edge detection algorithm of magnetic tile crack based on wavelet modulus maxima[J]. Journal of University of Electronic Science and Technology of China, 2015, 44(2): 283-288.
- [3] 林丽君, 殷鹰, 李雪琴, 等. 基于轮廓波包变换的磁瓦表面缺陷提取[J]. 应用基础与工程科学学报, 2016(2): 402-417.
LIN Li-jun, YIN Ying, LI Xue-qin, et al. Defect extraction on magnetic tile surface based on contourlet packet transform[J]. Journal of basic science and engineering, 2016(2): 402-417.
- [4] 杨成立, 殷鸣, 向召伟, 等. 基于非下采样 Shearlet 变换的磁瓦表面缺陷检测[J]. 四川大学学报(工程科学版), 2017, 49(2): 217-224.
YANG Cheng-li, YIN Ming, XIANG Zhao-wei, et al. Defect detection in magnetic tile Images based on non-subsampled shearlet transform[J]. Journal of Sichuan University (engineering science edition), 2017, 49(2): 217-224.
- [5] PARK J K, KWON B K, PARK J H, et al. Machine learning-based imaging system for surface defect inspection[J]. International journal of precision engineering and manufacturing-green technology, 2016, 3(3): 303-310.
- [6] GIBERT X, PATEL V M, CHELLAPPA R. Deep multi-task learning for railway track inspection[M]. New Jersey: IEEE Press, 2017.
- [7] CHA Y J, CHOI W, BÜYÜK Z, et al. Deep learning-based crack damage detection using convolutional neural networks[J]. Computer-aided civil and infrastructure engineering, 2017, 32(5): 361-378.
- [8] MEI S, WANG Y, WEN G. Automatic fabric defect detection with a multi-scale convolutional denoising auto-encoder network model[J]. Sensors, 2018, 18(4): 1064.
- [9] DUONG B P, KIM J. Non-mutually exclusive deep neural network classifier for combined modes of bearing fault diagnosis[J]. Sensors, 2018, 18(4): 1129.
- [10] HUANG H W, LI Q T, ZHANG D M. Deep learning based image recognition for crack and leakage defects of metro shield tunnel[J]. Tunnelling & underground space technology, 2018, 77: 166-176.
- [11] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation [C]//International conference on medical image computing and computer-assisted intervention. Freiburg: Springer, 2015: 234-241.
- [12] 徐江川. 基于深度卷积神经网络的熟料颗粒方法研究 [D]. 合肥: 中国科学技术大学, 2018.
XU Jiang-chuan. Analysis of clink particles based on DCNN[D]. Hefei: University of Science and Technology of China, 2018.
- [13] KUDO Y, AOKI Y. Dilated convolutions for image classification and object localization[C]//2017 fifteenth IAPR international conference on machine vision applications (MVA). Nagoya: IEEE, 2017: 452-455.
- [14] WANG P, CHEN P, YUAN Y, et al. Understanding convolution for semantic segmentation[C]//IEEE winter conference on applications of computer vision. Lake Tahoe: IEEE, 2017.
- [15] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//2nd information technology, networking, electronic and automation control conference. Chengdu: IEEE, 2015.
- [16] LIU Y, CHENG M M, HU X, et al. Richer convolutional features for edge detection[C]//Computer vision and pattern recognition. Florida: IEEE, 2017: 5872-5881.
- [17] BENJAMINI Y, HOCHBERG Y. Controlling the false discovery rate: A practical and powerful approach to multiple testing[J]. Journal of the Royal Statistical Society, 1995, 57(1): 289-300.
- [18] 张国翊, 胡铮, 徐婷. 基于特征提取的缺陷图像分类方法[J]. 北京工业大学学报, 2010, 36(4): 450-457.
ZHANG Guo -yi, HU Zheng, XU Ting. Classification method for defect image based on feature extraction[J]. Journal of Beijing University of Technology, 2010, 36(4): 450-457.