

DOI: 10.19650/j.cnki.cjsi.J2108652

# 基于轻量级卷积神经网络的带钢表面缺陷识别\*

李丹, 王慢慢, 刘俊德, 陈凤

(安徽工业大学电气与信息工程学院 马鞍山 243032)

**摘要:**带钢表面缺陷识别对促进带钢生产质量提升至关重要。然而传统的图像处理与识别方法存在精度不高、且容易受到光线等因素影响;而新兴的基于深度学习的算法,则存在模型参数量大且难以部署等问题,无法在实际生产中得到广泛应用。本文提出了一种轻量级部分深度混合可分离网络(PDMSNet)用于解决以上问题,由于其模型小以及浮点型运算(FLOPs)少更易于部署在资源受限的平台。采用标准的带钢表面缺陷数据集 NEU-CLS 的测试结果表明,与其他缺陷分类器相比,在带钢表面缺陷检测方面,本文所提出的模型性能更加优越。识别准确率达到99.78%,而参数量只有0.17 M以及272 M FLOPs,在单一低端的 GeForce MX250 图形处理单元(GPU)识别一张图片平均时间为0.47 ms,可以满足工业现场实时检测的要求。

**关键词:**带钢表面缺陷分类;轻量级网络;深度混合可分离模块;部分拼接模块

中图分类号: TP391.41 TH164 文献标识码: A 国家标准学科分类代码: 520.20

## Steel surface defect recognition based on a lightweight convolutional neural network

Li Dan, Wang Manman, Liu Junde, Chen Feng

(College of Electrical and Information Engineering, Anhui University of Technology, Ma'anshan 243032, China)

**Abstract:** Recognition of steel surface defect is essential to promote the improvement of steel production quality. However, the traditional image processing and recognition methods have low accuracy and are easily affected by factors such as light. However, the emerging algorithms based on deep learning have problems such as large amount of model parameters and difficulty in deployment, which cannot be widely used in practical production. In this article, a lightweight partial depth mixture separable network (PDMSNet) is proposed, which is small model size and floating-point operations (FLOPs) and is easy to deploy on resource-constrained platforms. The test results of the standard strip steel surface defect data set NEU-CLS show that the performance of the proposed model is better than other defect classifiers in strip steel surface defect detection. The recognition accuracy reaches 99.78%, and the number of parameters is only 0.17 M and 272 M FLOPs. The average time of an image recognition on a single low-end GeForce MX 250 GPU is 0.47 ms, which can meet the requirements of real-time detection in industrial field.

**Keywords:** classification of steel surface defects; lightweight network; depth mixture separable module; partial splicing module

## 0 引言

带钢是生产生活中必不可少的材料,但是由于原材料和工艺的问题,带钢在生产过程中会产生各种类型的缺陷。表面缺陷是影响钢材质量的主要因素之一,它降低了钢板强度、缩短了工件寿命、增加了安全风险。目前,常规的带钢表面缺陷识别人工检测方法效率低、准确

性差且容易受到检测人员的主观因素影响。因此研究高效率的缺陷智能识别算法对于实现带钢质量监控具有重要意义。

目前主流的缺陷识别<sup>[1]</sup>方法主要有传统方法和深度学习。基于统计信息和图像特征的传统缺陷分类<sup>[2]</sup>,噪声和光线等因素会影响分类的可靠性,并且识别结果很大程度上依赖于特征生成过程。因此在工业生产过程中应用范围有限。

收稿日期:2021-09-30 Received Date: 2021-09-30

\* 基金项目:安徽省自然科学基金(2108085MF225)项目资助

随着卷积神经网络<sup>[3]</sup>在图像识别和目标检测等视觉任务中取得了突破性进展,被广泛应用于钢铁产品的自动缺陷检测(automated defect inspection, ADI)中。文献[4]和文献[5]将卷积神经网络模型应用于带钢表面缺陷分类任务中。其中文献[4]对带钢表面缺陷的识别率达到了98.6%,文献[5]实现了97.2%的识别准确度。以往的工作证明,构建更深更复杂的卷积神经网络可以有效提高模型精度。由于一些关键技术的提出,例如残差连接(skip connection, SC)<sup>[6]</sup>和批量归一化(batch normalization, BN)<sup>[7]</sup>,训练一个几百层以上的网络变得很简单。但是更大的模型会导致推理上的高延迟,在计算受限的平台上难以部署。

## 1 理论分析

无论是基于传统的图像特征还是基于卷积神经网络的缺陷检测技术<sup>[8]</sup>,都在寻求高精度高效率的识别算法。然而带钢表面缺陷存在类间相似性和类内多样性等问题,给缺陷的识别带来了很大困难。在带钢表面缺陷识别任务中,文献[9]提出一种改进的基于迁移学习的VGG19网络,针对缺陷特征提取算法对于高亮度缺陷识别效果较差的问题,提出最大平均特征提取模块,识别准确率达到了97.8%。文献[10]在ResNet50-vd模型上引入可变形卷积dcn-v2增加物体变形的适应性,解决了传统卷积无法在对象被放大或旋转时进行自适应改变的问题,该方法的准确率可达97.52%。虽然这两种方法识别准确率达到了工业要求,但是由于VGG19和ResNet50都属于大模型,在实际应用中对于计算平台要求更高。

近年来,轻量级网络因其更少的模型参数,更快速有效的模型训练,在嵌入式系统或中小型设备中得到了一定的应用。例如,MobileNet<sup>[11]</sup>使用深度可分离卷积进行构建。深度可分离卷积通过分解卷积的形式,将标准卷积分解为两层:一层用于滤波,一层用于组合。这种分解方式显著减少了计算量和模型大小,但是带来了精度的损失。在图像缺陷识别领域,小卷积核倾向于获取较低分辨率的特征,常用 $3\times 3$ 卷积;更大的卷积核倾向于以更多的参数和计算量为代价,从而获取丰富的高分辨率特征,常用卷积核为 $5\times 5$ 、 $7\times 7$ 等。Tan等<sup>[12]</sup>设计了替换单深度卷积的方法,在一个深度卷积运算中混合不同大小的卷积核,来捕获输入图像中不同分辨率的特征,在增加少量参数和计算量的情况下提高了模型精度。在综合考虑计算量和识别精度的前提下,卷积核尺寸以及混合数量的选择可以根据待识别缺陷类型,通过实验结果来确定。ShuffleNet<sup>[13]</sup>利用两种新的操作,逐点组卷积和通道洗牌(channel shuffle, CS),在保持精度的同时大大降低了计算成本。CSPNet<sup>[14]</sup>通过将基础层的特征映射划分

为两部分,然后通过提出的跨阶段层次结构将他们组合起来,通过这种方式实现了网络更丰富的梯度组合并且有效的减少了计算量。

基于以上分析,本研究设计了一种PDMSNet模型,该模型参数量更少、训练速度更快、只需要少量的特定缺陷训练样本就能实现准确的缺陷识别。为了验证PDMSNet模型性能,我们将所提出的模型在公共数据集(NEU-CLS)<sup>[15]</sup>上与其他现有缺陷分类方法从参数量和识别精度等方面进行比较,以验证本文方法的有效性。

## 2 方法

文献[16]提出的SqueezeNet用更少的参数同时保持了准确率,是一种先进的轻量级网络体系结构。该方法在ImageNet数据集上实现了57.5%的Top-1和80.3%的Top-5精度,相比于AlexNet参数量减少了50倍。SqueezeNet的提出,为我们的研究提供了很好的启示。SqueezeNet主要由挤压层和扩展层组成的fire模块(如图3(a)所示)构建。挤压层使用 $1\times 1$ 卷积减少输入特征通道,同时将扩展层中部分 $3\times 3$ 卷积换成 $1\times 1$ 卷积,有效的减少了模型参数<sup>[16]</sup>。然而如图2(a)所示,随着网络加深通道数量大幅提升, $3\times 3$ 卷积依旧会产生很多参数量,需要进一步优化。在此,本文设计了部分深度混合可分离(partial depthwise mix separable, PDMS)模块,如图2(b)所示,在本实验的网络模型中共有两个部分深度混合可分离模块,即:PDMS1和PDMS2。

PDMS由深度混合可分离(depthwise mix separable, DMS)模块和部分拼接模块组成。如图2(b)所示( $c_1, c_2$ 为特征图完整通道, $c_1', c_2'$ 是经过通道分离操作后的一半特征通道,C表示拼接操作),部分拼接模块将基础层的一半特征通道送入m-fire层,然后和整个特征图拼接并将结果送入下一阶段。本实验在PDMS1和PDMS2模

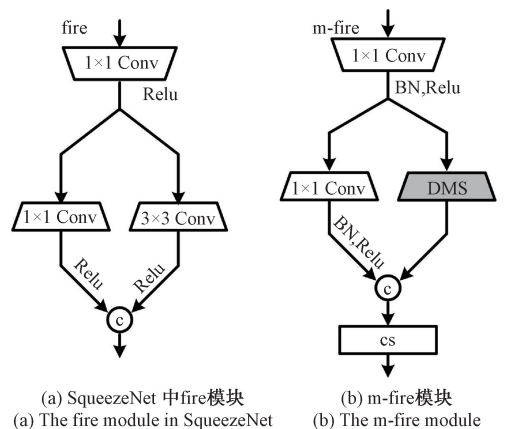


图1 fire模块和m-fire模块

Fig. 1 Fire module and m-fire module

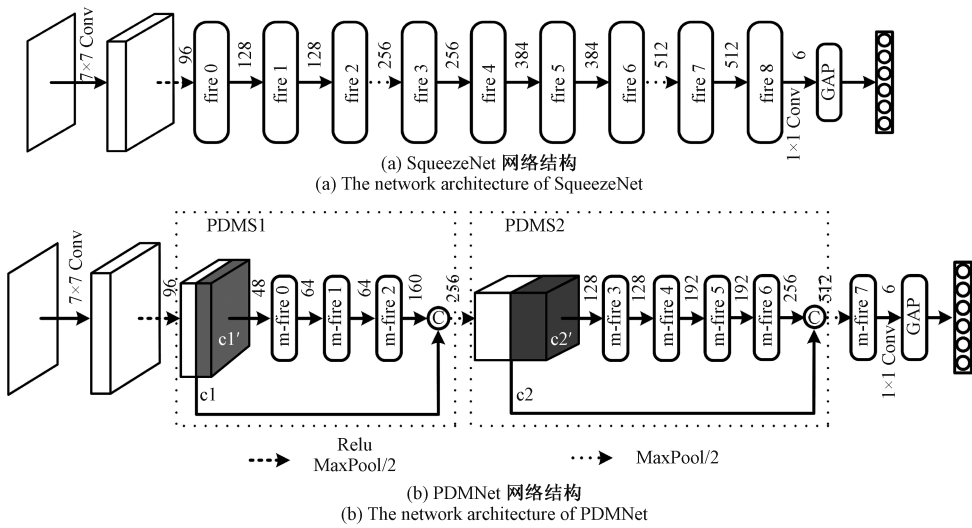


图2 SqueezeNet 和 PDMSNet 的整体结构图

Fig. 2 The overall architectures of SqueezeNet and PDMSNet

块的开始加入通道分离,然后将一半特征通道( $c1'$ ,  $c2'$ )送入 m-fire 层得到输出后和整体通道( $c1$ ,  $c2$ )拼接,称之为部分拼接模块。在下文 2.1 节中详细介绍了 PDMS 模块,以及在 2.2 节中详细说明了部分拼接模块。

## 2.1 深度混合可分离模块

卷积运算<sup>[17]</sup>产生的参数量为  $D_k \times D_k \times M \times N$ ,其中  $D_k$  假设为卷积核的空间维度,  $M$  是输入特征通道数,  $N$  是输出特征通道数。因此减少特征通道可以有效减少卷积运算产生的参数量。Howard 等<sup>[11]</sup>提出了深度可分离卷积将标准卷积分解为深度卷积和  $1 \times 1$  逐点卷积,深度卷积对每个输入通道应用一个卷积核有效的减少了大卷积核操作的参数量。在设计具有深度卷积核的卷积网络时,一个重要的但经常被忽略的因素是核的大小。在最近的研究中表明,单一的内核大小在获得输入图像特征时具有局限性<sup>[12]</sup>。MixNet<sup>[12]</sup>已经证明不同尺寸卷积操作可以捕获不同分辨率的特征,从而有效的提高模型精度。

基于此本工作在深度可分离卷积的深度卷积中混合多种卷积核,称为深度混合可分离模块(DMS)。如图3所示,图中C表示拼接操作,CS表示通道洗牌操作。将输入特征通道分组,每组应用不同尺寸的卷积核,当组数为1时,相当于深度可分离卷积<sup>[11]</sup>。图中所示将输入通道分成三组,每组卷积核大小分别为  $3 \times 3$ 、 $5 \times 5$  和  $7 \times 7$ 。对于每个组的信道大小参考 MixNet,考虑两种划分方式:1) 相等的划分:每组具有相同数量的通道;2) 指数划分:第  $i$  组大约有总通道的  $2^{-i}$  个通道<sup>[12]</sup>。然而多组卷积叠加有一个副作用:来自某个通道的输出仅来自那一个输入通道<sup>[13]</sup>。从图3混合深度卷积(mix\_depthwise)输出特征图中很容易看出这种缺陷。为削弱这种副作用,首

先将每个卷积核得到的特征图先执行 CS 操作,使不同尺寸卷积核得到的特征进行融合,然后再执行拼接操作。在此之后通过逐点卷积层的  $1 \times 1$  卷积进行通道提升。这种 DMS 模块能够显著减少计算量和模型大小,通过增加不同尺寸的卷积核使得特征提取变得更丰富,有效的提高了模型精度。




图3 DMS 模块

Fig. 3 DMS module

如图1(b)所示,原始 fire 模块中,将左右两侧  $1 \times 1$  卷积和  $3 \times 3$  卷积的特征图执行拼接操作,通过对比可以发现,本工作的 m-fire 模块保留了拼接操作,并对融合后的特征图执行 CS 操作以加强两个分支之间的信息流通<sup>[14]</sup>。

## 2.2 部分拼接模块

PDMS 模块中部分拼接模块如图4所示( $c1$  为特征图完整通道,  $c1'$  是经过通道分离操作后的一半特征通道。C 表示拼接操作),前层网络输出的特征图经过通道分割(channel split)操作,一半通道  $c1'$  通过  $1 \times 1$  卷积降采样后进入 m-fire 模块。由于所涉及的操作通道仅占原始通道数的一半,因此可以解决近一半的计算量。最后将输出和整个通道  $c1$  进行拼接,可以被视为一种功能重用,其思想与 DenseNet<sup>[18]</sup>相似。ShuffleNetV2 已经证明

特征重用率随着两个块之间距离呈指数衰减,在距离较远的块之间,特征重用率变得更弱<sup>[19]</sup>。因此可以通过重复使用特征以获得高精度,同时通过分裂合并策略,可以使梯度路径的数目翻倍。




图 4 部分拼接模块

Fig. 4 Partial splicing module

在图 1(b) PDMSNet 模型中 m-fire1、m-fire3、m-fire4、m-fire5、m-fire7 输入和输出具有相同维度,本工作采用跳跃连接将它们的输入输出直接相加。因此,在前向传播时,输入信号可以从底层直接传到较高层,一定程度上可以缓解网络退化问题;反向传播时,错误信号可以不经任何中间权重矩阵变换直接传播到下一层,在一定程度上缓解了梯度弥散问题<sup>[20]</sup>。

综上所述,本文在 Squeezenet 模型基础上提出了 PDMSNet 模型。提出 DMS 模块,通过混合多个不同尺寸卷积核捕获不同分辨率的特征;引入分裂合并思想,通过部分拼接模块可以增加梯度路径。

### 3 实验与结果分析

在本节中,我们使用公共的带钢表面缺陷数据集 NEU-CLS<sup>[15]</sup>,来验证 PDMSNet 网络模型性能。

#### 3.1 数据集以及参数设置

钢铁表面缺陷数据集 (NEU-CLS)<sup>[15]</sup> 由东北大学宋克臣等发布。NEU-CLS 数据库包含 1 800 张分辨率为 200×200 像素的灰度图像,其中包含了热轧带钢表面的 6 种典型缺陷,即裂纹 (crazing, Cr)、夹杂 (inclusion, In)、斑块 (patches, Pa)、点蚀面 (pitted surface, PS)、轧制氧化皮 (rolled in Scale, RS) 和划痕 (scratch, Sc)。每种典型表面缺陷 300 个样例。通过对数据库图片分析可见,表面缺陷分类存在两大难题,即类内缺陷在外观上存在较大差异,类间缺陷在外观上存在相似性,且缺陷图像受到光照和材料变化的影响。图 5 为 6 种典型表面缺陷的样本图像。

本实验将原始数据集按 5:3:2 随机划分为训练集、验证集和测试集,希望使用一个小的数据集训练网络模型,评估网络架构。将验证集用于调整模型的超参数,并对模型性能进行初步评估,验证当前模型泛化能力,最后使用测试集评估最终模型的泛化能力。




图 5 NEU-CLS 中不同缺陷类别的图像示例

Fig. 5 Image examples of different defect categories in NEU-CLS

所有的实验采用 Windows10 操作系统,基于 Python3.7 的 Pytorch1.7.0 框架下实现,使用单个 NVIDIA GeForce MX250 完成。输入图像大小被设置为 224×224,使用随机梯度下降法 (SGD) 训练模型,动量设为 0.9。根据 GPU 内存和数据集大小,批处理大小 (batch size) 设置为 16。实验通过训练集对网络进行了 200 个 epochs 的训练,初始学习率设置为 0.01,其中每隔 60 个 epochs 学习率衰减 10 倍。本节所有实验数据为平均 5 次运算所得。

#### 3.2 评价指标

本工作选取了精确度 (precision)、准确率 (accuracy)、召回率 (recall)、F1 分数 (F1-score) 等评价指标对模型性能进行验证。为了衡量模型计算复杂度,我们使用浮点运算的数量,即 FLOPs。表 1 所示为混淆矩阵,其中真阳性 (TP) 表示正类样本被正确识别为正类;真阴性 (TN) 表示负类样本被正确识别为负类;假阳性 (FP) 表示负类样本被错误识别为正类;假阴性 (FN) 表示正类样本被错误识别为负类。

表 1 混淆矩阵

Table 1 Confusion matrix

真实分类	预测分类	
	正类	负类
正类	TP	FN
负类	FP	TN

*Precision* 定义为式 (1) 所示,表示在被预测为正类的样本中,实际为正类样本所占的比例。*Precision* 是查准率的测量,该值越大越好。

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

*Accuracy* 表示分类正确的样本占总样本的比例,如式 (2) 所示。其中 TP+TN 为所有正确预测为负类和正类的总和,通常来说准确率越高,分类器越好。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

*Recall* 的定义如式 (3) 所示,表示在全部正样本中识

别正确的正样本所占的比例。 $TP+FN$  即为总样本中所有为正类的总数。

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$F_{1-score}$  是分类问题的一个衡量指标,它认为查全率和查准率同等重要,它是  $Recall$  和  $Precision$  的调和平均值,其公式如式(4)所示。

$$F_{1-score} = 2 \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

### 3.3 消融实验

为了阐述本工作所提 DMS 模块和部分拼接模块的有效性,采用 SqueezeNet 作为基线网络,在 NEU 独立验

证集上的测试结果如表 2 所示, $\Delta$ , $Cum\Delta$  分别表示准确度增益和累积增益,BN 和 SC 分别表示批量归一化和残差连接。从表 2 中可以看出,SqueezeNet 识别精度波动较大,仅实现了 63.94% 的平均准确率。为此,本工作引入 BN 和 SC,使得 5 次实验的识别结果更加稳定,且精度提高了 35.61%。深度可分离卷积的引入,将模型参数从 744 262 降为 255 942,然而准确度减少了 0.16%。DMS 模块使识别准确度提升了 0.50%,而仅仅增加了 5 504 的参数量。部分拼接模块保持了 99.89% 的高识别准确度,同时参数量从 261 446 降为 168 014,FLOPs 降为 272 M。因此可以看出本工作有效的提高了模型的识别性能,同时减少了大量的参数以及 FLOPs。

表 2 在 NEU 独立验证集上的消融实验

Table 2 Ablation experiments on the NEU independent validation set

方法 Method	参数量 Params	浮点型运算 FLOPs/M	准确率 Accuracy/%	准确度增益 $\Delta$	累积增益 Cum $\Delta$
Squeezenet	738 502	743.53	63.94 $\pm$ 23.07	0	0
+BN,SC	744 262	749.61	99.55 $\pm$ 0.28	+35.61	+35.61
+深度可分离卷积	255 942	360.57	99.39 $\pm$ 0.11	-0.16	+35.45
+深度混合可分离模块	261 446	366.27	<b>99.89<math>\pm</math>0.09</b>	+0.50	+35.95
+部分拼接模块	168 014	272.00	<b>99.89<math>\pm</math>0.09</b>	0	+35.95

为验证 DMS 模块中卷积核组合方式对带钢缺陷识别性能的影响,将 SqueezeNet+DMS 网络模型在 NEU 的验证集上进行实验。图 6 所示为实验结果,本实验将 DMS 模块的卷积核从  $3 \times 3$  开始,每组卷积核尺寸逐渐增加 2。 $k3 \times 3$  表示 DMS 模块中只有  $3 \times 3$  一种卷积核; $k5 \times 5$  表示 DMS 模块中混合了  $3 \times 3$  和  $5 \times 5$  两种卷积核; $k7 \times 7$  表示 DMS 中混合了  $3 \times 3$ 、 $5 \times 5$ 、 $7 \times 7$  这 3 种卷积核; $k9 \times 9$  中混合了 4 种卷积核,分别为  $3 \times 3$ 、 $5 \times 5$ 、 $7 \times 7$  和  $9 \times 9$ 。图中虚线为 DMS 模块中不同卷积核组合方式的准确率指标,实线为 FLOPs 指标。从图 6 中可以发现,随着卷积核组合的增加,识别精度先增加后减少,当卷积核组合增加到 4 种时,准确率从 99.89% 下降为 99.70%;同时 FLOPs 从 366.27 M 增加为 371.03 M,增幅比较明显。验证了在带钢缺陷识别中,当卷积核的混合尺寸增加到  $9 \times 9$  不但没有提升性能,反而引起了准确率的下降。

为了进一步验证卷积核的尺寸以及混合数量的选取对于不同缺陷的影响,将拥有不同卷积核的 SqueezeNet+DMS 网络模型用于 NEU 独立测试集中,分别测试其对于带钢 6 种典型缺陷的识别性能。识别结果如表 3 所示,通过表 3 可以明显地看出,随着卷积核尺寸的增加,夹杂、点蚀面、划痕这 3 种缺陷的准确率、召回率、F1 分数

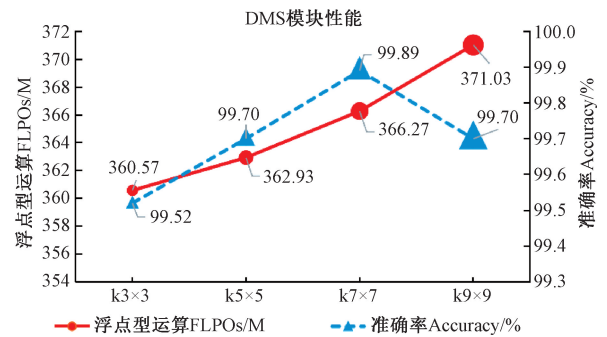


图 6 DMS 模块性能

Fig. 6 DMS module performance

先依次升高,而当卷积核尺寸组合为 3,5,7,9 时识别性能降低明显。尽管卷积核组合为 3,5,7,9 的模型对裂纹这一缺陷识别表现出较好的性能,但是在其他五种缺陷中,其识别性能劣于组合为 3,5,7 的模型。

通过图 6 和表 3 的性能比较,卷积核组合方式为 3,5,7 的网络模型不仅在整体识别准确率中取得了最高结果,而且在 6 种缺陷的识别性能中取得了最优的权衡,因此最终选择卷积核尺寸为 3,5,7 的组合方式。

SqueezeNet+DMS 中  $3 \times 3$ 、 $5 \times 5$ 、 $7 \times 7$  尺寸的卷积组合(以下简称 SqueezeNet+DMS)识别精度最高,但是会增加

表 3 在 NUE 独立测试集的 6 种缺陷的识别性能对比

Table 3 Comparison of recognition performance of six kinds of defect in the NUE independent test set

卷积核 尺寸	裂纹			夹杂			斑块			点蚀面			轧制氧化皮			划痕		
	准确 率	召回 率	F1 分数	准确 率	召回 率	F1 分数	准确 率	召回 率	F1 分数	准确 率	召回 率	F1 分数	准确 率	召回 率	F1 分数	准确 率	召回 率	F1 分数
3	99.67	100	99.83	98.33	98.33	98.33	100.00	100.00	100.00	98.33	98.00	98.16	100	100	100	100	100.00	100.00
3,5	99.35	100	99.67	99.01	98.00	98.50	99.67	99.67	99.67	98.02	98.67	98.33	100	100	100	100	99.67	99.83
3,5,7	99.67	<b>100</b>	99.83	<b>100.00</b>	<b>99.00</b>	<b>99.50</b>	<b>100.00</b>	<b>100.00</b>	<b>100.00</b>	<b>99.02</b>	<b>99.67</b>	<b>99.34</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100.00</b>	<b>100.00</b>
3,5,7,9	100.00	100	100.00	97.70	99.00	98.34	100.00	100.00	100.00	99.00	98.00	98.49	100	100	100	100	99.67	99.83

少量的网络模型参数和占用内存。因此在网络模型中引入部分拼接模块即 PDMSNet 模型,同时为了验证部分拼接模块的有效性,在 NEU 的验证集进行了实验。结果如图 7 所示,T(Ture)和 F(False)分别表示 DMS 中加入部分拼接模块和不加入部分拼接模块。在 DMS 模块 1 和 2 中同时增加部分拼接模块(PDMS1 和 PDMS2 模块),识别准确度高于只增加一个部分拼接模块的网络模型,同时有效的降低了模型参数量。跟 SqueezeNet+DMS 相比,参数量从 0.26 M 降为 0.17 M,同时保持了 99.89%的识别准确度,FLOPs 最低为 272 M。

3.4 模型泛化性能比较

本节将在 NEU 数据集的独立测试集上验证 PDMSNet 模型的泛化性能。本工作比较了原始 SqueezeNet, SqueezeNet+BN, SC, SqueezeNet+深度可分离卷积, SqueezeNet+DMS 以及最终的网络模型 PDMSNet (T,T) (以下简称为 PDMSNet) 来验证本次工作的有效性。如表 4 中所示,无论是精度还是参数量,PDMSNet 网络模型都取得了最优的结果。具体为:和原始 SqueezeNet 模型精度相比,PDMSNet 模型精度提升了 43.42%;参数量从 738 502 减少为 168 014,缩小了 4.4 倍;而且 FLOPs 相比于原始 SqueezeNet 减少了 2.7 倍不止;PDMSNet 识别一张图片的平均时间为 0.47 ms。充分说明了 PDMSNet 模型更简洁,识别效果更好。

为了进一步证明本工作所提方法的有效性,将 PDMSNet 模型和经典的分类模型如:ResNet18<sup>[20]</sup>网络, MixNet<sup>[12]</sup>网络和 MobileNetV3<sup>[21]</sup>网络进行了性能对比。结果如表 5 所示,在带钢的缺陷分类中,我们希望精确度和准确率越高越好,通过比较发现,PDMSNet 模型无论是精确度还是准确率都比 MixNet 要高 0.27%左右。然而 PDMSNet 的参数量只有 ResNet18 的 1/65,大约是 MixNet 和 MobileNetV3 的 1/24。无论是召回率还是 F1 分数都取得最好的结果,综合考虑 PDMSNet 模型在 NEU 数据集上的识别性能更好。

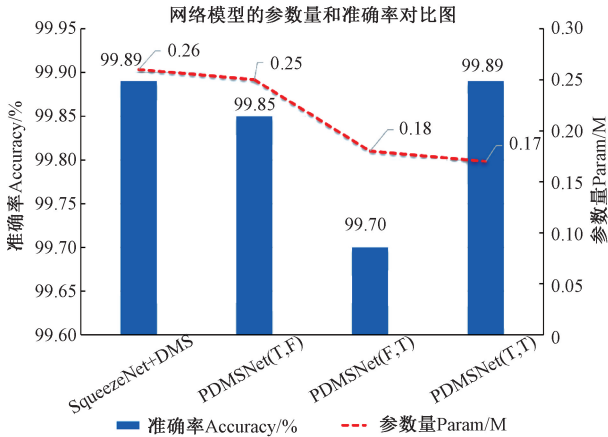


图 7 部分拼接模块性能

Fig. 7 Partial splicing module performance

表 4 NEU 独立测试集识别结果

Table 4 NEU independent test set identification results

方法 Method	精确度 Precision/%	准确率 Accuracy/%	召回率 Recall/%	F1 分数 F <sub>1-score</sub> /%	参数量 Params	浮点型运算 FLOPs/M	识别时间 T/ms
SqueezeNet	56.36±25.92	63.94±23.07	63.94±23.07	56.83±26.86	738 502	743.53	0.59
SqueezeNet+BN, SC	99.56±0.28	99.55±0.28	99.55±0.28	99.55±0.28	744 262	749.61	0.59
SqueezeNet+深度可分离卷积	99.39±0.11	99.39±0.11	99.39±0.11	99.39±0.11	255 942	360.57	0.51
SqueezeNet+深度混合可分离模块	99.78±0.11	99.78±0.11	99.78±0.11	99.78±0.11	261 446	366.27	0.55
PDMSNet	<b>99.78±0.11</b>	<b>99.78±0.11</b>	<b>99.78±0.11</b>	<b>99.78±0.11</b>	<b>168 014</b>	<b>272.00</b>	<b>0.47</b>

表5 在 NEU 测试集上与先进网络模型分类结果的比较

Table 5 Comparison with advanced network model classification results on the NEU test set

方法 Method	精确度 Precision/%	准确率 Accuracy/%	召回率 Recall	F1 分数 F <sub>1</sub> -score	参数量 Params/M	浮点型运算 FLOPs
MobileNetV3	99.03±0.32	99.00±0.33	99.00±0.33	99.00±0.33	4.21	226.44M
ResNet18	99.28±0.13	99.28±0.13	99.28±0.13	99.28±0.13	11.18	1.82G
MixNet	99.51±0.27	99.50±0.27	99.50±0.27	99.50±0.27	4.13	251.82M
文献 <sup>[9]</sup>	—	97.62	—	—	—	—
文献 <sup>[22]</sup>	98.50	98.25	98.10	98.30	—	—
文献 <sup>[23]</sup>	—	99.05	—	—	1.25	—
文献 <sup>[24]</sup>	—	99.61	—	—	41.89	7.3B
PDMSNet	<b>99.78±0.11</b>	<b>99.78±0.11</b>	<b>99.78±0.11</b>	<b>99.78±0.11</b>	<b>0.17</b>	<b>272.00M</b>

图8将测试集用于PDMSNet模型混淆矩阵的评估,从而系统地研究6种不同缺陷类别的分类结果。在这个混淆矩阵中,每一行是实际的缺陷类别,每一列对应着预测的预测结果。所有正确的预测都位于表格的对角线上,这样很容易直观的检查识别结果中的错误。从图中可以看到6种缺陷样本中,只有一张夹杂(In)被错误的识别为点蚀(PS),其余5种缺陷裂纹(Cr)、斑块(Pa)、点蚀面(PS)、轧制氧化皮(RS)和划痕(Sc)全部预测正确。

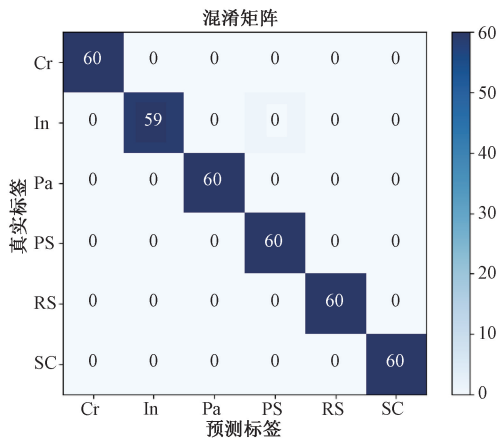


图8 PDMSNet在NEU独立测试集的混淆矩阵

Fig. 8 PDMSNet confusion matrix in the NEU independent test set

## 4 结 论

本文在Squeezenet网络模型基础上,提出一种基于卷积神经网络的PDMSNet模型,以解决以往工作中模型参数量大,特征提取不充分的问题。通过在DMS模块中混合多种尺寸卷积核,用于捕获多种分辨率特征,有效的提高了模型精度。同时为了减少模型参数,加入部分拼

接模块将输入通道减半,缓解了近一半的参数量。通过这两种策略,有效的提高了模型分类准确度,同时降低了参数量。实验结果表明,PDMSNet在0.47ms的延迟和较低的训练成本下,缺陷分类准确度达到了99.78%,完全满足工业生产的实时性要求。未来本工作继续尝试将该模型用于带钢表面的缺陷检测中。

## 参考文献

- [1] 邱根,王锂,白利兵. 基于生成对抗网络数据扩充的缺陷识别方法[J]. 电子测量与仪器学报, 2021, 35(2): 212-220.  
QIU G, WANG L, BAI L B. GANs-based synthetic data augmentation for defects recognition[J]. Chinese Journal of Scientific Instrument, 2021, 35(2): 212-220.
- [2] 李绍丽,苑玮琦,杨俊友,等. 基于局部二值差异激励模式的木材缺陷分类[J]. 仪器仪表学报, 2019, 40(6): 68-77.  
LI SH L, YUAN W Q, YANG J Y, et al. Wood defect classification based on local binary difference excitation pattern[J]. Chinese Journal of Scientific Instrument, 2019, 40(6): 68-77.
- [3] 毛向向,王红军,韩风霞,等. 基于深度卷积神经网络的机电系统故障分类识别方法[J]. 电子测量与仪器学报, 2021, 35(2): 87-93.  
MAO X X, WANG H J, HAN F X, et al. Fault classification and recognition of electromechanical system based on deep convolutional neural network[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2): 87-93.
- [4] WANG C, LIU Y T, YANG Y N, et al. Research on

- classification of surface defects of hot-rolled steel strip based on deep learning [J]. *DEStech Transactions on Computer Science and Engineering*, 2019; 375-379.
- [ 5 ] HE D, XU K, ZHOU P, et al. Surface defect classification of steels with a new semi-supervised learning method[J]. *Optics and Lasers in Engineering*, 2019,117: 40-48.
- [ 6 ] ORHAN A E, PITKOW X. Skip connections eliminate singularities [ J ]. *ArXiv Preprint*, 2017, *ArXiv*: 1701.09175.
- [ 7 ] LIANG S, KHOO Y, YANG H. Drop-Activation; Implicit parameter reduction and harmonious regularization [ J ]. *Communications on Applied Mathematics and Computation*, 2021, 3(2): 293-311.
- [ 8 ] 陶晓天, 何博侠, 张鹏辉, 等. 基于深度学习的航天密封圈表面缺陷检测[J]. *仪器仪表学报*, 2021, 42(1): 199-206.
- TAO X T, HE B X, ZHANG P H, et al. Surface defect detection of aerospace sealing rings based on deep learning[J]. *Chinese Journal of Scientific Instrument*, 2021, 42(1): 199-206.
- [ 9 ] WAN X, ZHANG X Y, LIU L L. An improved vgg19 transfer learning strip steel surface defect recognition deep neural network based on few samples and imbalanced datasets[J]. *Applied Sciences*, 2021, 11(6): 2606.
- [ 10 ] WANG S, XIA X, YE L, et al. Automatic detection and classification of steel surface defect using deep convolutional neural networks[J]. *Metals-Open Access Metallurgy Journal*, 2021, 11(3): 388.
- [ 11 ] HOWARD A G, ZHU M, CHEN B, et al. MobileNets; Efficient convolutional neural networks for mobile vision applications [ J ]. *ArXiv Preprint*, 2017, *ArXiv*: 1704.04861.
- [ 12 ] TAN M, LE Q V. MixConv; Mixed depthwise convolutional kernels[J]. *Arxiv Preprint*, 2019, *ArXiv*: 1907.09595.
- [ 13 ] ZHANG X, ZHOU X, LIN M, et al. ShuffleNet; An extremely efficient convolutional neural network for mobile devices [ C ]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018; 6848-6856.
- [ 14 ] WANG C Y, LIAO H, WU Y H, et al. CSPNet; A new backbone that can enhance learning capability of CNN[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2020;1571-1580.
- [ 15 ] HE Y, SONG K, MENG Q, et al. An end-to-end steel surface defect detection approach via fusing multiple hierarchical features [ J ]. *IEEE Transactions on Instrumentation and Measurement*, 2019; 1493-1504.
- [ 16 ] IANDOLA F N, HAN S, MOSKEWICZ M W, et al. SqueezeNet; AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size [ J ]. *Arxiv Preprint*, 2016, *Arxiv*:1602.07360.
- [ 17 ] 蓝金辉, 王迪, 申小盼. 卷积神经网络在视觉图像检测的研究进展[J]. *仪器仪表学报*, 2020, 41(4): 167-182.
- LAN J H, WANG D, SHEN X P. Research progress of convolutional neural network in visual image detection [J]. *Chinese Journal of Scientific Instrument*, 2020,41(4): 167-182.
- [ 18 ] HUANG G, LIU Z, LAURENS V, et al. Densely connected convolutional networks [ J ]. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017; 2261-2269.
- [ 19 ] MA N, ZHANG X, ZHENG H T, et al. ShuffleNet V2; Practical guidelines for efficient CNN architecture design[C]. *Proceedings of the European Conference on Computer Vision (ECCV)*, 2018; 116-131.
- [ 20 ] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [ C ]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016; 770-778.
- [ 21 ] HOWARD A, SANDLER M, CHU G, et al. Searching for MobileNetV3 [ C ]. *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2019; 1314-1324.
- [ 22 ] HU J, YAN P, SU Y, et al. A Method for classification of surface defect on metal workpieces based on twin attention mechanism generative adversarial network[J]. *IEEE Sensors Journal*, 2021, 21(12): 13430-13441.
- [ 23 ] YI L, LI G, JIANG M. An end - to - end steel strip



surface defects recognition system based on convolutional neural networks[J]. Steel Research International, 2017, 88(2): 176-187.

- [24] XING J, JIA M. A convolutional neural network-based method for workpiece surface defect detection [J]. Measurement, 2021, 176:109185.

## 作者简介



**李丹** (通信作者), 1997 年于安徽工业大学获得学士学位, 2004 年于安徽工业大学获得硕士学位, 2008 年于南京航空航天大学获得博士学位, 现为安徽工业大学教授, 主要研究方向为图像处理、机器视觉和自主导航。

E-mail: lidan@ahut.edu.cn

**Li Dan** (Corresponding author) received her B. Sc. degree and M. Sc. degree both from Anhui University of Technology in 1997 and 2004, and received her Ph. D. degree from Nanjing University of Aeronautics and Astronautics in 2008. She is currently a professor at Anhui University of Technology. Her main research interests include image processing, machine vision and autonomous navigation.



**王慢慢**, 2020 年于安徽工业大学工商学院获得学士学位, 目前于安徽工业大学攻读硕士学位, 主要研究方向为图像处理计算机视觉和深度学习。

E-mail: 1902609429@qq.com

**Wang Manman** received her B. Sc. degree from Industrial & Commercial College, Anhui University of Technology in 2020. She is currently pursuing her master degree at Anhui University of Technology. Her main research interests include image, processing computer vision and deep learning.



**刘俊德**, 2020 年于铜陵学院获得学士学位, 目前于安徽工业大学攻读硕士学位, 主要研究方向为图像处理、计算机视觉和深度学习。

E-mail: ljd1606@163.com

**Liu Junde** received his B. Sc. degree from Tongling University in 2020. He is currently pursuing his master degree at Anhui University of technology. His main research interests include image processing, computer vision and deep learning.



**陈凤**, 2015 年于河北师范大学获得学士学位, 目前于安徽工业大学攻读硕士学位, 主要研究方向为机器视觉与三维重建。

E-mail: hellochenf@163.com

**Chen Feng** received her B. Sc. degree from Hebei Normal University in 2015. She is currently pursuing her master degree at Anhui University of technology. Her main research interests include machine vision and three-dimensional reconstruction.