

# 基于多尺度残差网络优化的工业品表面缺陷检测

陈昕卓, 李建军, 张超

(内蒙古科技大学 信息工程学院, 内蒙古 包头 014010)

**摘要:** 工业品表面缺陷检测是工业产品质量评估的关键环节, 实现快速、准确、高效的检测对提升工业产能具有重要意义; 该研究针对传统神经网络提取特征尺度单一、参数量大, 网络训练效率低等问题, 提出了一种基于残差网络的多尺度特征融合与RBN结合的残差网络模型; 首先该模型通过多尺度卷积特征融合模块提取不同尺度的特征信息; 然后, 通过引入RBN层, 使特征分布更加均匀; 最后, 采用全局平均池化代替传统的全连接层来减少模型的参数量, 实现输出通道与特征类别的直接映射; 该研究提出的网络模型在公开数据集 NEU-DET 上进行实验, 识别率达到 100%, 在天池人工智能大赛铝型材缺陷数据集上的识别率达到 98.8%, 模型性能较为优异, 可以很好地完成工业品表面缺陷检测任务。

**关键词:** 工业品表面缺陷检测; 多尺度特征; RBN; 全局平均池化

## Surface Defect Detection of Industrial Products Based on Multi-scale Residual Network Optimization

CHEN Xinzhuo, LI Jianjun, ZHANG Chao

(College of Information Engineering, Inner Mongolia University of Science and Technology, Baotou 014010, China)

**Abstract:** Surface detection of industrial products is the key link of quality assessment. Rapid, accurate and efficient detection is significantly realized to improve industrial capacity. In this research, based on the combination of multi-scale feature fusion and RBN, a residual network model is proposed to solve the problems of traditional neural networks, such as single feature scale extraction, large number of parameters and low network training efficiency. Firstly, the multi-scale convolution feature fusion module is used to extract the feature information of different scales. Then, by introducing RBN layer, the distribution of feature server is more uniform. Finally, global average pooling is replaced by the traditional full connection layer to reduce the parameters of the model, so the direct mapping between output channels and feature categories is realized. In this paper, the proposed network model was tested on the open data set (NEU-DET), and 100% of the recognition rate is reached. The recognition rate on aluminum product defect data set for Tianchi artificial intelligence competition reached to 96.67%. The model has excellent performance and can effectively complete the industrial product surface defect detection.

**Keywords:** industrial product surface defect detection; multi-scale features; RBN; global average pooling

### 0 引言

随着我国工业的蓬勃发展, 我国已进入制造大国行列。近年来, 随着我国“工业 4.0”和“中国制造 2025”等战略目标的提出以及制造业数字化、网络化、智能化的普及, 工业品供应商对其产品的质量把控越来越严。在工业品生产线上, 表面缺陷检测技术是保障工业品质量、性能和提高企业综合竞争力的关键。目前工业品缺陷检测的方法可以概括为以下 3 类: 1) 采用传统的人工方法检测产品表面, 耗费大量人力、物力资源, 费时且效率低下; 人工处理具有较强的主观性, 检测的准确率无法得到保障; 2) 采用传统的机器学习的方法提取特征进行缺陷检测时, 主要任务量集中于图像预处理、提取特征、特征分类器设计。

此类方法过度依赖人为设计的特征提取与分类方法, 并且需要通过大量的实验进行参数调节和阈值设定, 准确率随外界环境波动较大, 误差率较高<sup>[1-4]</sup>; 3) 基于卷积神经网络 (CNN) 的检测方法, 该方法以经典的卷积神经网络为基础进行图像处理, 进而生成特征图, 最后完成缺陷检测, 但是工业品表面缺陷复杂多样、缺陷区域大小不一、种类和程度均不相同, 使得深度神经网络在工业品表面检测领域的应用受到了限制<sup>[5-7]</sup>。

基于卷积神经网络的检测和分类方法近年来已取得较好发展, Krizhevsky 等<sup>[8]</sup>在 2012 年提出 AlexNet 网络模型, 该模型由 5 个卷积层、3 个全连接层和 3 个池化层构成, 采用 BN 层加快收敛速度、采用 Dropout 防止过拟合。在 IL-

收稿日期: 2021-09-14; 修回日期: 2021-11-01。

基金项目: 国家自然科学基金资助项目(62066036, 51965052)。

作者简介: 陈昕卓(1992-), 男, 黑龙江齐齐哈尔人, 硕士研究生, 主要从事人工智能、模式识别方面的研究。

通讯作者: 李建军(1978-), 男, 内蒙古乌兰察布人, 博士, 副教授, 硕士生导师, 主要从事人工智能、模式识别方面的研究。

引用格式: 陈昕卓, 李建军, 张超. 基于多尺度残差网络优化的工业品表面缺陷检测[J]. 计算机测量与控制, 2022, 30(4): 29-34.

SRVC 大规模视觉识别挑战赛中斩获冠军, top5 数据集预测的错误率为 16.4%。Li 等<sup>[9]</sup>简化了 AlexNet 模型的参数并用于钢板表面的缺陷分类, 通过网络训练学习缺陷特征, 避免了特征提取与图像分类分离的问题, 形成了端到端的缺陷识别, 分类准确率达 99.05%。

K. M. He 等<sup>[10]</sup>在 2015 年提出了 ResNet 网络, 基于 Basic Block 层数的不同, 将残差网络分为 ResNet18、ResNet34、ResNet50、ResNet101、ResNet152 共 5 个类型, 通过 downsample 使输入与输出尺寸相统一, 利用恒等映射原理, 可以使网络进一步地加深而不会导致网络梯度消失和爆炸, 也不会增加误差。获得当年 CVPR 大赛第一名, 在 ImageNet 测试集上达到了 96.32% 的准确率。何<sup>[11]</sup>等人提出了基于 ResNet34 的弱监督钢板缺陷分类检测系统, 分类准确率达 93.2%。

He 等<sup>[12]</sup>通过采用残差网络 (ResNet34、ResNet50) 在每个阶段生成的特征图, 提出多级特征融合网络 (MFN), 进行钢板表面缺陷检测, 该方法可以在单个 GPU 上以 20fps 的速度进行检测, 缺陷检测任务的准确率达到 82.3%。

基于以上基础。本文针对现有网络模型复杂、特征尺度单一、参数过多、难以训练、网络收敛速度慢等问题, 在 ResNet 网络模型的基础上提出了一种多尺度残差融合模型。其主要创新点包括:

1) 在特征提取方面, 为避免输入特征尺度单一、特征信息丢失。使用多尺度特征融合网络模型, 将卷积核分别设置为  $5 \times 5$ 、 $7 \times 7$ 、 $9 \times 9$  提取多尺度特征信息。

2) 针对神经网络中全连接层参数量大, 导致的收敛速度慢, 且易产生过拟合等问题。在网络模型中, 采用全局平均池化层替代全连接层。防止网络的过拟合, 加强特征图与类别的一致性, 加快网络收敛速度。

3) 为了提高神经网络中 BatchNorm<sup>[13]</sup> 模块对图像进行批量归一化能力, 避免样本之间差异过大的问题, 使用 Representative BatchNorm<sup>[14]</sup> 层代替 BatchNorm 层, 在原 BatchNorm 层的基础上增加中心校准和缩放校准环节。增强特征信息并削弱噪声, 提高分类任务的准确率。

本文所提出的网络, 在东北大学钢板缺陷数据集 NEU-CLS 进行实验分析, 相比现有技术, 得到了比现有检测更高的识别准确率, 因此, 将该项技术应用于实际生产中, 将会进一步提升产品的质量保障, 提升产品竞争力。

## 1 多尺度残差融合模型

### 1.1 多尺度特征融合模块

在运用残差网络 ResNet 时, 由于特征提取尺度的单一性, 存在特征信息丢失的现象。针对这个问题, 提出多尺度特征融合模块提取图像中不同尺度的特征。本文提出的多尺度特征融合模块的基本思想是运用多个不同的卷积核提取多尺度特征, 采用并联三通道结构, 并将多个卷积操作提取的特征图融合, 最终构成了完整的多尺度特征提取模块。该模块的结构如图 1 所示。

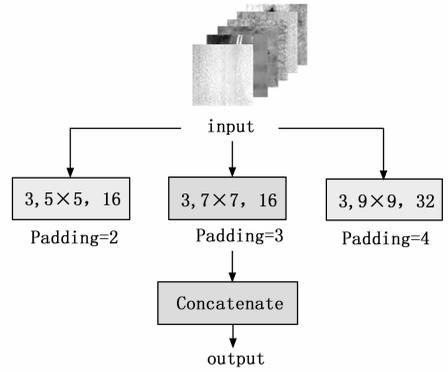


图 1 多尺度特征融合模块结构示意图

多尺度特征提取与融合模块主要分为两个部分: 多尺度特征提取部分、多尺度特征融合部分。

1) 多尺度特征提取部分采用并联三通道结构, 且各分支结构卷积核不同。卷积核大小分别为  $5 \times 5$ 、 $7 \times 7$  和  $9 \times 9$ , 不同尺寸的卷积核对不同尺度的特征进行提取, 既保留浅层的细节信息又融合了深层信息。

2) 特征融合部分是将多尺度特征提取层提取的多个特征图进行融合, 运用 Concatenate 使多通道提取的特征图拼接成一个完整的特征图。最后融合成的特征图的输出通道数为各分支输出通道数之和。在融合过程中, 为保证输出特征图大小一致, 采用 padding 填充特征图边缘区域。多尺度特征提取与融合模块原理如图 2 所示。

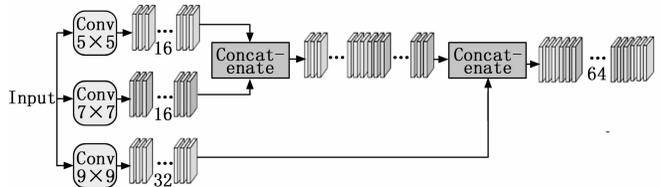


图 2 多尺度特征提取与融合模块原理图

### 1.2 全局平均池化

在使用卷积神经网络进行分类任务时, 全连接层通常作为神经网络的最后一层。该层存在大量的参数, 导致计算量增大, 极大地限制了神经网络的收敛速度, 且易产生过拟合等问题。为解决上述问题, 一般会在全连接层设置 Dropout, 按照一定的概率随机失活一些网络单元, 减弱神经元之间的依赖性, 增加网络的泛化能力。但是采用 Dropout 会增加网络的训练时间, 并且不易设置最优参数。

全局平均池化 (GAP, global average pooling)<sup>[15]</sup> 不以小窗的形式滑动, 而是在上一层输出的整张特征图上进行全局均值化, 将特征图转化为一个特征向量, 输入的每一层特征图由特征向量的每一个数值表示, 其原理如图 3 所示。使用全局平均池化层对整张特征图所有值求平均, 可以充分利用每张特征图的信息提取关键特征并减少计算量。本文利用全局池化层代替残差网络中的最大池化层, 将特征向量导入残差网络的输出层进行求解, 即可获得分类结果, 减少了参数量, 不需要优化参数, 提高了网络训练效

率, 减轻了拟合程度。因此, 运用 GAP 代替全连接层有助于提高网络性能, 提升识别率。

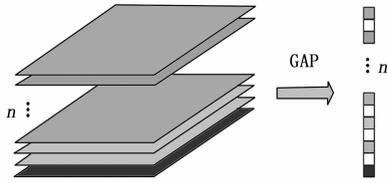


图 3 全局平均池化原理图

### 1.3 RBN 模型

#### 1.3.1 BN

BatchNorm 模块能加速神经网络的收敛并提升识别准确率, 因而被广泛使用。Batch-Norm 由特征居中、特征缩放和放射变换 3 个步骤实现。给定输入特征  $x \in R^{N \times C \times H \times W}$ , 其中  $N$ 、 $C$ 、 $H$ 、 $W$  为 batch 的大小、通道数、输入特征的高度和宽度。特征居中、缩放、仿射公式如下:

$$x_m = x - \mu \quad (1)$$

$$x_s = \frac{x_m}{\sqrt{\sigma + \epsilon}} \quad (2)$$

$$Y = \gamma x_s + \beta \quad (3)$$

式中,  $x_m$  为 feature map 中心,  $x_s$  为特征缩放值,  $Y$  为仿射变换后的结果,  $\gamma$  是用来调整数值分布的方差大小,  $\beta$  是用来调节数值均值的位置。 $\gamma$ 、 $\beta$  是由反向传播过程中学习得到,  $\gamma$  的默认值是 1,  $\beta$  的默认值是 0。 $\mu$  和  $\sigma$  为 feature map 所有像素值点总数的平均值和方差, 在归一化的过程中, 使其满足均值为 0, 方差为 1 的分布, 其公式为:

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i \quad (4)$$

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2 \quad (5)$$

式中,  $\mu$  为像素点总数的平均值,  $\sigma$  为像素点总数的方差值;  $x_i$  为该图像样本中第  $i$  个像素点值;  $n$  表示该样本总像素点数,  $\epsilon$  为保证分母恒大于 0 的常数值。

BN 通过归一化方程对样本进行归一化操作将数据规整到统一的区间, 减轻了数据的发散度, 降低了网络的学习难度。且在一定程度上保留原数据的分布。

#### 1.3.2 RBN

通过 BatchNorm 的均值和方差归一化处理使得神经网络的训练更加稳定, 通过使用小批量统计信息将中间特征限制在归一化分布内, 从而减轻了训练难度, 但在归一化过程中忽略了样本之间的表示差异。为了解决上述问题, 提出了 RBN (representative batch normalization) 模型, 其中 RBN 分为两个步骤: 1) 中心化校准 (centering calibration); 2) 缩放校准 (scaling calibration)。中心化步骤是为了增强信息特征, 减少噪声; 缩放步骤是为了让特征服从一个稳定的分布, 其原理如图 4 所示。

1) 中心化校准。中心化校准在原 BatchNorm 层的居中操作前添加中心校准环节。若给定输入特征为  $X$ , 定心校准

准如式 (6) 所示:

$$X_m = X + \omega_m \odot K_m \quad (6)$$

式中, 输入特征  $X \in R^{N \times C \times H \times W}$ ,  $X_m$  为定心校准值, 其中  $N$ 、 $C$ 、 $H$ 、 $W$  为 batch 的大小、通道数、输入特征的高度和宽度。 $\omega_m$  是一个形状为  $(N, C, 1, 1)$  的可学习变量,  $K_m$  是各个实例特征的统计量且  $K_m \in R^{N \times C \times H \times W}$ ,  $\odot$  是将两个特征散步同一形状的点积运算符。通过定心校准后, feature map 的中心公式为:

$$X_M = X_m - E(X_m) \quad (7)$$

式中,  $X_M$  为特征中心,  $E(X_m)$  为中心校准后的均值。

2) 缩放校准。缩放操作是添加在特征缩放之后的校准环节, 可对特征的方差进行缩放, 并得到特征的单位方差。然而, 均值缩放会导致特征强度不稳定, 即某些通道的特征远大于其他通道的特征。因此, 在缩放操作后采用缩放校准来校准特征强度。缩放校准公式如下:

$$X_s = X_s \cdot R(\omega_v \odot K_s + \omega_b) \quad (8)$$

式中,  $\omega_v$ 、 $\omega_b \in R^{1 \times c \times 1 \times 1}$  是可学习变量,  $R(\cdot)$  为限制函数, 本文采用 Sigmoid 函数作为限制函数抑制极值,  $K_s$  是实例特征  $X_s$  的统计量。

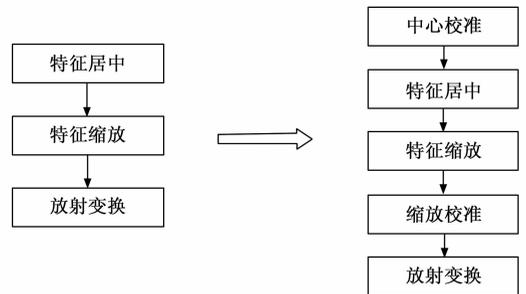


图 4 BN (左) 和 RBN (右) 工作流程图

RBN 采用了简单而有效的特征校准方案, 保留了样本中各实例的特征, 并产生了更稳定的特征分布。定心校准增强了信息特征并削弱了噪声; 缩放校准限制了特征强度以形成更稳定的特征分布。用 RBN 取代 BN 可较大幅度地提高神经网络模型的性能。

### 1.4 改进的残差网络模型

#### 1.4.1 ResNet 网络的优缺点

随着深度学习的发展, 自 AlexNet 网络诞生以来, 许多学者选择通过加深网络深度的方法解决目标检测、分类等任务, 虽然取得了较好的效果, 但也带来了一些问题:

1) 传统的卷积神经网络由一系列卷积层与下采样层进行堆叠得到, 在浅层网络叠加到一定深度时, 会产生梯度消失和梯度爆炸问题。导致网络反向传播过程中无法对前面的网层权重进行有效的调整。

2) 在深度模型上增加更多的网层会导致网络退化的现象, 即随着网络深度的增加, 准确性达到饱和, 然后迅速下降。这是由于冗余的网层学习了非恒等映射的参数造成的。

ResNet 网络通过引入一个深度残差学习框架解决了深

层网络梯度消失（爆炸）的问题，使用 shortcut 的连接方式，进行恒等映射，不会产生额外的参数，也不会增加计算复杂度。以 ResNet18 为例，ResNet18 共有 18 层，网络输入为  $224 \times 224$ ，通过卷积和最大池化操作，图像降维到  $56 \times 56$ ，且通道数保持不变。完成前两步操作后进入残差模块，每经历一部分残差模块图像降维一半，通道数则增加到原通道数的二倍，通过 4 次残差网络的处理，图像降维到  $7 \times 7$ ，此时通道数为 512，最后连接平均池化层和全连接层。

ResNet 虽然解决了梯度消失（爆炸）的问题，也可以避免随着网层的叠加而导致的网络退化现象。但在工业品表面缺陷检测与分类的使用场景下，仍存在特征提取尺度单一、模型参数多、资源需求大、收敛速度慢等缺陷。

### 1.4.2 改进的 ResNet 网络

通过设计多尺度特征提取模块，充分提取深浅层的特征信息，并且随着网络宽度的增加，可以有效缓解训练样本有限的问题。全局平均池化层代替全连接层，减少了参数量，提高了网络训练效率，减轻了残差网络过拟合程度。

在每个残差块中，当输入通过卷积操作后，采用 RBN 层代替 BN 层，通过中心化校准和缩放校准，增强信息特征，减少噪声，并使特征分布更加均匀。再通过线性整流函数（ReLU, rectified linear unit）进行激活，最后通过卷积层和 RBN 层的处理得到输出，设计框图如图 5 所示。

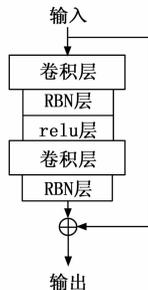


图 5 残差块设计框图

该网络首先使用多尺度特征提取和融合模块对原图像进行卷积操作学习特征，然后添加 RBN 层进行数据的归一化处理，保证网络性能的稳定。然后采用线性整流函数，以提高该模块的非线性映射能力，函数关系如下式所示：

$$f_i(x) = \omega_i * x + b_i \quad (9)$$

$$f(x) = \sigma \left\{ \text{BN} \left[ \sum_{i=1}^3 f_i(x) \right] \right\} = \sigma \left\{ \text{BN} \left[ \sum_{i=1}^3 (\omega_i * x + b_i) \right] \right\} \quad (10)$$

其中： $x$  表示多尺度特征提取模块的输入； $f_i(x)$  为第  $i$  个卷积层的输出； $\omega_i$  和  $b_i$  分别表示该模块的第  $i$  个卷积层的权重和偏置；“ $*$ ”表示卷积操作； $\sigma(\cdot)$  表示 ReLU 激活函数。最后将得到的  $f(x)$  作为 ResNet 的输入。

将残差网络结构分为 4 个阶段（当输出空间大小或输出通道数要改变时，标志着另一个阶段的开始）。每个阶段

有 2 个 BasicBlock，在网络末端使用全局平均池化层代替全连接层。网络模型架构如图 6 所示。

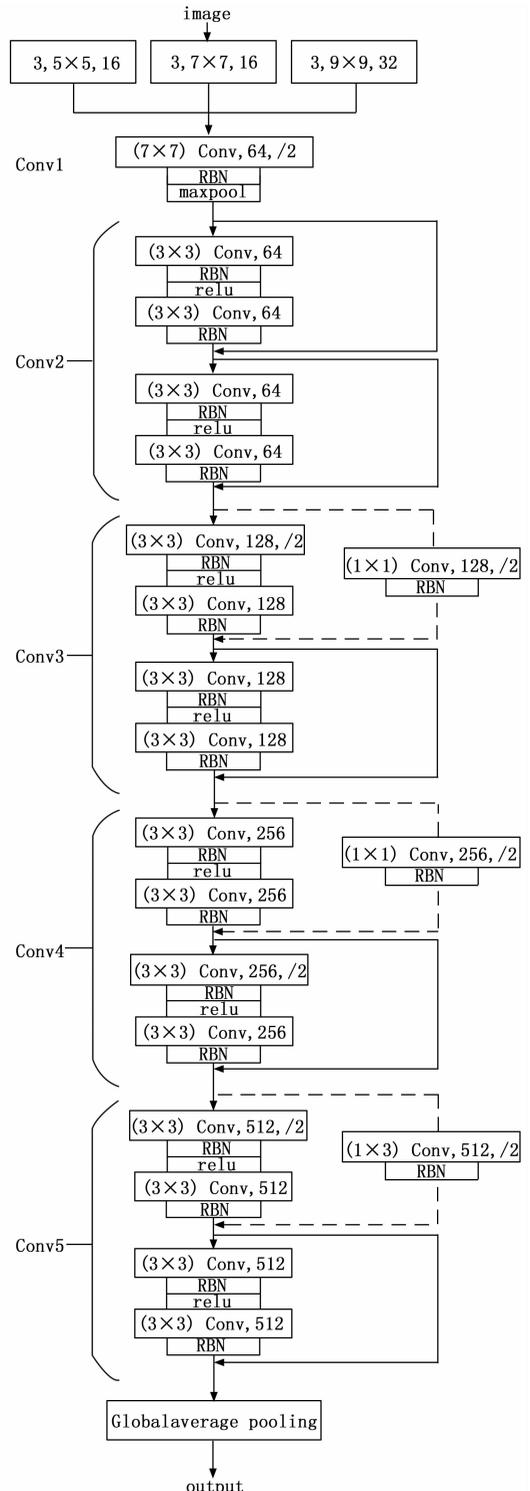


图 6 改进的 ResNet 网络结构图

## 2 实验结果分析

### 2.1 NEU-CLS 数据集

本文的实验在东北大学公开的钢板表面缺陷数据集 NEU-CLS 上进行，该数据集涵盖了 6 类常见的热轧钢板表

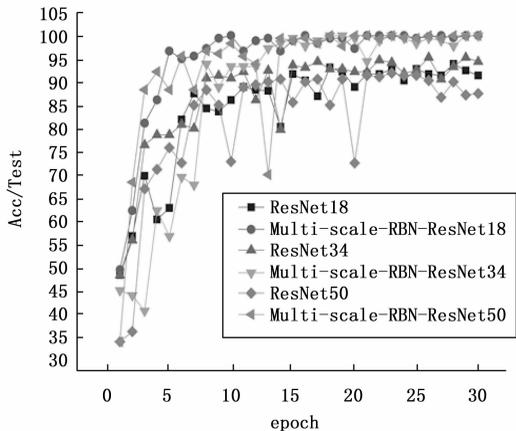
面缺陷, 分别为轧制氧化皮 (RS), 斑块 (Pa), 开裂 (Cr), 点蚀表面 (PS), 内含物 (In) 和划痕 (Sc) 该数据集共有 1 800 张样本, 每个类别 300 张。训练集与测试集的比例设置为 8 : 2。

### 2.2 实验平台

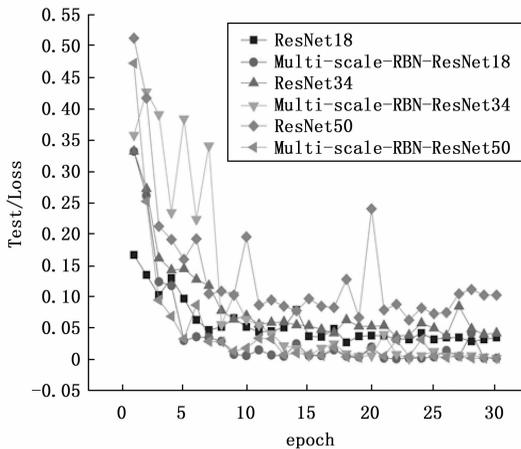
以搭载 Intel 酷睿 i7-11700kF CPU, 内存大小 32G, Nidia 1660GPU 的计算机作为实验硬件基础, 实验软件环境基于 Windows10 操作系统、pytorch1.6 深度学习框架、python3.7 搭建的缺陷检测框架。

### 2.3 实验结果与分析

在原有 ResNet18、ResNet34、ResNet50 上进行改进, 采用多尺度输入代替单一尺度输入, 通过 RBN 层代替 BN 层, 通过平均池化层代替全连接层得到 Multi-scale-RBN-ResNet 网络。将 Multi-scale-RBN-ResNet 模型和原有 ResNet 模型进行对比实验, 在非迁移学习的情况下, 训练时每次读取数据的样本数为 batch size=8, 本文提出的网络模型在该数据集上迭代 30 次 (epoch=30), 实验结果如图 7 所示。



(a) 准确率对比图



(b) 损失函数结果对比图

图 7 NET-CLS 数据集实验结果对比图

由图可知, 随着迭代次数的增加, 各模型的测试准确率也随之提高, 最终接近 100%。其中, 本文提出的模型明

显优于传统残差网络模型, 在不使用迁移学习的情况下, 分类准确率可达到 100%。其中, Multi-scale-RBN-ResNet18 收敛速度最快, 并且相对稳定, 模型的识别性能最为优异。

该数据集来源于实际生产中带有表面缺陷的钢板并已完成图像预处理: 将尺寸归一到 200×200、对噪声进行去除、并完成二值化操作, 使得缺陷检测过程中受外界干扰较小, 检测的准确率达 100%。

本文提出的 Multi-scale-RBN-ResNet18 网络模型和使用 NEC-CLS 数据集的其他方法在分类准确率上的对比实验, 结果如表 1 所示。

表 1 本文模型与其他的检测方法对比实验

Method	Accuracy/%
Dong H <sup>[11]</sup>	82.15
He Y <sup>[12]</sup>	92.00
Gao Y <sup>[13]</sup>	90.70
Yi L <sup>[4]</sup>	99.05
本文模型	100.00

其中, 在文献 [16] 中, 提出了一种金字塔特征融合和全局注意力网络, 用于表面缺陷检测; 在文献 [17] 中, 根据基线卷积神经网络在每个阶段生成的特征地图, 提出多级特征融合网络 (MFN) 用于融合更多深度信息; 在文献 [13] 中, 提出了一种基于卷积神经网络的钢表面缺陷半监督学习方法, 该方法需要的标记样本较少, 并利用伪标签对 CNN 进行了改进; 在文献 [18] 中, 提出一种用于带钢表面检测的端到端表面缺陷识别系统。该系统基于对称的环绕显著图进行表面缺陷检测, 深度卷积神经网络直接以缺陷图像作为输入, 以缺陷类别作为输出; 可对数据集中的 6 类缺陷和无缺陷钢板进行分类。本文提出的模型取得了最高的识别准确率, 验证了该模型的有效性。

为了验证本文提出的网络模型对不同工业品表面缺陷的测试效果, 选取阿里天池比赛的铝型材表面缺陷数据集, 并结合铝型材在生产过程中的常见缺陷类别进行实验验证。大赛数据集里有 1 万份来自实际生产中有瑕疵的铝型材监测图像数据, 本文随机选取其中的 8 个瑕疵类别, 每个类别包含 200 个数据。训练集和测试集的比例设置为 8 : 2。原始样本瑕疵种类如图 8 所示。

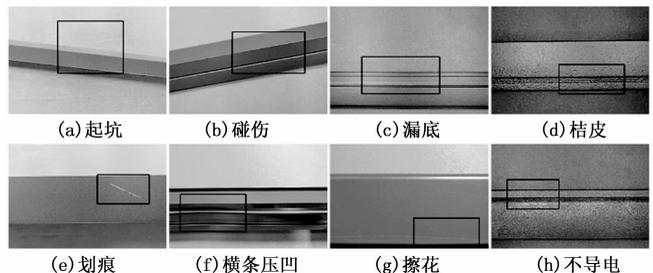


图 8 铝型材表面缺陷数据集

在铝型材缺陷数据集上叠加 30 个 epoch, 将本文提出的模型与 AlexNet<sup>[19]</sup>、VGG16<sup>[20]</sup> 和 ResNet 模型进行对比, 如图 9 所示。由图可知, 对于橘皮、划痕、擦花缺陷种类, 缺陷信息较为接近, 且铝型材的制造与加工处于工况复杂的场景下, 通过小样本和细节缺陷信息的输入, 网络分类准确率仍可达到 98.8%。与 AlexNet、VGG16 和 ResNet 网络模型相比, Multi-scale-RBN-ResNet18 在准确率和收敛速度两方面均得到了极大限度的提升。

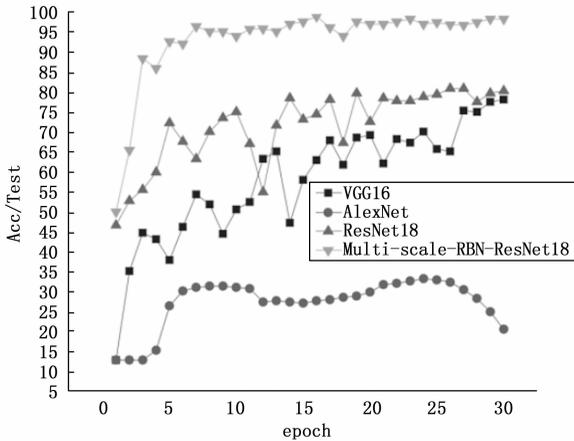


图 9 铝型材数据集测试准确率对比图

### 3 结束语

本文针对工业品表面缺陷检测任务, 在 ResNet 模型的基础上, 添加多尺度特征融合模块, 利用多尺度卷积提取更多尺度的特征; 然后, 采用 RBN 层代替 BN 层, 增强了特征信息; 最后使用全局平均池化代替全连接层, 使输出与特征类别映射更加直观, 并简化了网络模型。在 NEU-CLS 数据集上识别率达 100%, 在阿里天池铝型材表面数据集上识别率达 98.8%。实验结果表明, 改进后的网络模型对工业品表面缺陷检测效果比较理想, 性能优于其他同类模型。

#### 参考文献:

[1] LIU K, WANG H, CHEN H, et al. Steel surface defect detection using a new Haar-Weibull-variance model in unsupervised manner [J]. IEEE Transactions on Instrumentation and Measurement, 2017, 66 (10): 2585-2596.

[2] 洪存存, 王雪琨, 于文文, 等. 基于改进双边滤波的皮革缺陷检测 [J]. 激光技术, 2021, 45 (3): 373-377.

[3] 王冬云, 唐楚, 鄂世举, 等. 基于导向滤波 Retinex 和自适应 Canny 的图像边缘检测 [J]. 光学精密工程, 2021, 29 (2): 443-451.

[4] 王雪平, 张建斐, 李万润, 等. 基于机器视觉的风电叶片风沙侵蚀程度检测方法研究 [J]. 太阳能学报, 2020, 41 (5): 166-173.

[5] LIU K, LUO N, LI A, et al. A new self-reference image decomposition algorithm for strip steel surface defect detection

[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69 (7): 4732-4741.

[6] 常颖, 常大俊. 改进型卷积神经网络焊点缺陷识别算法研究 [J]. 激光技术, 2020, 44 (6): 779-783.

[7] 刘畅, 张剑, 林建平. 基于神经网络的磁瓦表面缺陷检测识别 [J]. 表面技术, 2019, 48 (8): 330-339.

[8] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks [J]. Advances in Neural Information Processing Systems, 2012, 25 (2): 93-98.

[9] 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.

[10] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // IEEE Conference on Computer Vision & Pattern Recognition, IEEE Computer Society, 2016.

[11] 何璇, 宋克臣, 张德富, 等. 融合多层次特征的弱监督钢板表面缺陷检测算法 [J]. 东北大学学报 (自然科学版), 2021, 42 (5): 687-692.

[12] 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 (99): 1-1.

[13] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [J]. JMLR. org, 2015 (9): 1-9.

[14] GAO S H, HAN Q, LI D, et al. Representative batch normalization with feature calibration [J]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2001: 8669-8679.

[15] LIN M, CHEN Q, YAN S. Network in network [J]. Computer Science, 2013 (10): 1-10.

[16] DONG H, SONG K, HE Y, et al. PGA-Net: pyramid feature fusion and global context attention network for automated surface defect detection [J]. IEEE Transactions on Industrial Informatics, 2020, 16 (12): 7448-7458.

[17] 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 (99): 1.

[18] GAO Y, GAO L, LI X, et al. A semi-supervised convolutional neural network-based method for steel surface defect recognition [J]. Robotics and Computer Integrated Manufacturing, 2020, 61: 101825.1-101825.8.

[19] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. Computer Science, 2014 (14): 1-14.

[20] XIE S, GIRSHICK R, DOLLAR P, et al. Aggregated residual transformations for deep neural networks [J]. IEEE, 2016 (10): 1-10.