

# 一种基于注意力模型的带钢表面缺陷识别算法

陆雅诺<sup>1</sup>, 陈炳才<sup>1,2\*</sup>, 陈德刚<sup>1</sup>, 闫世祥<sup>1</sup>, 李顺平<sup>1</sup>

<sup>1</sup>新疆师范大学计算机科学技术学院, 新疆 乌鲁木齐 830054;

<sup>2</sup>大连理工大学计算机科学与技术学院, 辽宁 大连 116024

**摘要** 为了提高工业带钢的质量和产量, 针对传统人工识别难度大、效率低和客观性不够等问题, 提出了一种基于软注意力机制的带钢表面缺陷识别方法, 对传统深度残差网络 ResNet 模型进行了改进, 使用伪彩色图像增强技术处理图片, 得到了新的训练集。实验结果表明, 在不同信噪比情况下, 相比于传统的模型, 改进模型 A-ResNet50 和 A-ResNet101 都能准确识别不同类型的带钢表面缺陷图像, 在测试集上的准确率分别为 98.61% 和 98.05%, 单位推断时间达到了 0.078 s 和 0.130 s, 证实了 A-ResNet50 和 A-ResNet101 模型在带钢表面缺陷识别上的可行性以及可靠性。所提出的方法识别精度高, 实现了带钢表面缺陷的智能识别, 同时满足工业识别需求。

**关键词** 图像处理; 注意力机制; 伪彩色图像; 深度残差网络; 缺陷识别

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP202158.1410014

## Recognition Algorithm of Strip Steel Surface Defects Based on Attention Model

Lu Yanuo<sup>1</sup>, Chen Bingcai<sup>1,2\*</sup>, Chen Degang<sup>1</sup>, Yan Shixiang<sup>1</sup>, Li Shunping<sup>1</sup>

<sup>1</sup> School of Computer Science and Technology, Xinjiang Normal University, Urumqi, Xinjiang 830054, China;

<sup>2</sup> College of Computer Science and Technology, Dalian University of Technology, Dalian, Liaoning 116024, China

**Abstract** In order to improve the quality and output of industrial strip steels and address the problems of traditional manual identification such as identification difficulty, low efficiency and lack of objectivity, we propose a method for identifying strip steel surface defects based on the soft attention mechanism and improve the traditional deep residual network ResNet model. Moreover, we use the pseudo-color image enhancement technique to process images and obtain new training sets. The experimental results show that compared with the traditional models, the improved models of A-ResNet50 and A-ResNet101 can both accurately identify different types of strip steel surface defect images under different signal-to-noise ratios. The accuracies on the test set are 98.61% and 98.05%, and the unit inference time is 0.078 s and 0.130 s, respectively. Thus the feasibility and reliability of these two models in the identification of surface defects on strip steels are confirmed. The proposed method possesses a high identification accuracy, which can be used to realize the intelligent identification of surface defects on strip steels and meet the demands of industrial identification.

**Key words** image processing; attention mechanism; pseudo-color images; deep residual networks; defect identification

**OCIS codes** 100.2000; 120.4290; 100.4996; 150.1835

收稿日期: 2020-09-30; 修回日期: 2020-11-01; 录用日期: 2020-11-14

基金项目: 国家自然科学基金(61961040, 61771089)、新疆维吾尔自治区“天山青年计划”(2018Q024)、自治区区域协同创新专项(科技援疆计划)(2020E0247, 2019E0214)

通信作者: \*china@dlut.edu.cn

## 1 引言

带钢作为钢铁工业的重要原材料,其良好的表面质量和力学性能使其在汽车工业、航天工业和轻工制造等领域得到了广泛的应用<sup>[1]</sup>。近年来,各种基础设施建设对带钢的需求越来越高,而带钢受到结构和制作工艺的影响,容易出现多种表面缺陷,如裂纹、夹杂物、斑块和划伤等,这些缺陷在很大程度上影响了带钢的质量。因此,本文针对于带钢表面缺陷,提出了快速智能识别方法,以期在提高带钢质量的同时实现更小的次品率。

传统的人工检测方法采用钢板表面检测方法,一种是通过肉眼去观察带钢表面的缺陷,另一种则是抽检,前者具有局限性,后者具有不全面性。随着带钢产量的逐年稳定上升,为了提高产量和质量,研究者根据机器视觉<sup>[2]</sup>的高效、精确等特点,研究了带钢表面缺陷更深层的特征提取,利用迁移学习的方法进行智能识别,从而有效提高了带钢的生产质量。胡联亭<sup>[3]</sup>对传统 AdaBoost 算法进行改进,提出了 AdaBoost. BK 算法,并对特征和缺陷标签进行了学习和测试,最终得到了 85.89% 的分类精度。郭慧等<sup>[4]</sup>提出了径向基核函数支持向量机方法,对钢板表面各种缺陷的识别准确率达到 90% 以上。单东日等<sup>[5]</sup>提出了一种基于小波变换和灰度共生矩阵的带钢表面缺陷识别方法,通过将四方向灰度共生矩阵计算获得的特征值输入到支持向量机中,完成了

对带钢表面缺陷图像的识别,总体识别精度大于 96%。常江等<sup>[6]</sup>使用改进的生成对抗网络,生成了较为逼真的带钢缺陷图像,从而解决了深度学习中样本不足的问题。带钢表面缺陷的识别受光照、噪声的影响,容易出现识别精度不高的问题,陈小芳等<sup>[7]</sup>针对该问题提出了改进的 MB-LBP 特征算法,减小了融合特征冗余的影响,该算法具有一定的鲁棒性。

本文基于深度学习,在便于优化的 ResNet 网络中加入注意力模块,利用红绿蓝(RGB)三个通道的权重找到重要的特征通道,并进行了实验测试,提高了不同信噪比下带钢表面缺陷智能识别的准确度。

## 2 深度卷积网络模型与注意力机制

### 2.1 ResNet 网络

ResNet 是 He 等<sup>[8]</sup>提出的一个网络模型。ResNet 作为图像分类问题中的基础特征提取网络,使用了残差单元,减少了参数数量,并在网络中增加了直连通道,增加了卷积神经网络(CNN)对特征的学习能力。相比于之前的 VGG 网络,具有参数少、层数深和分类识别效果优秀等特点。带钢表面缺陷识别深度残差网络框架如图 1 所示,其中 Convolutional Layer 为卷积层, Pooling Layer 为池化层, RB1~RB4 为 Resnet Block 1~4, GlobalAvgPooling 为全局平均池化, FC Layers 为全连接层。

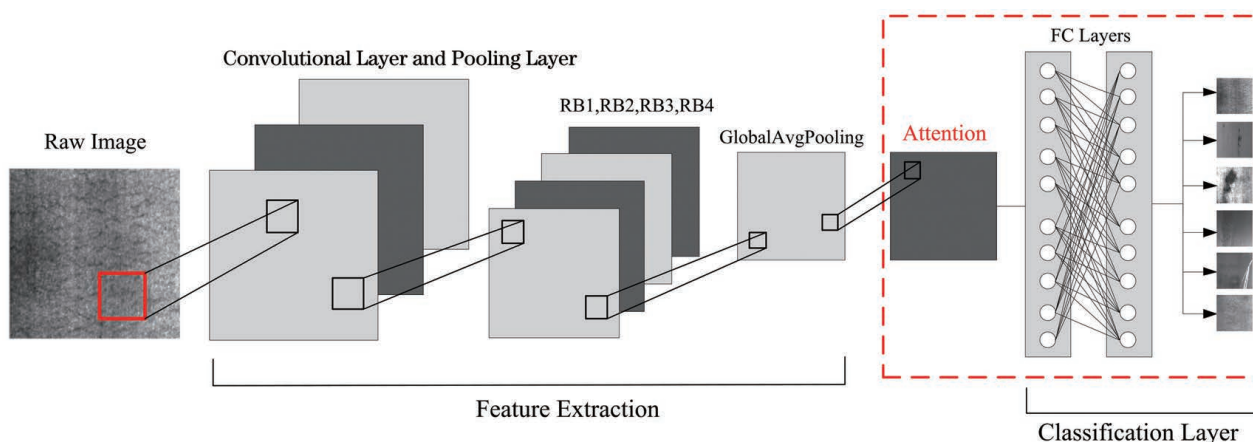


图 1 基于注意力机制的带钢表面缺陷识别深度残差网络框架

Fig. 1 Deep residual network frame for strip steel surface defect recognition based on attention mechanism

### 2.2 注意力机制概述

常见的注意力机制有两种类型,一种是通道注意力,如压缩激励(SE)模块<sup>[9]</sup>,一种是空间注意力,如空间变换器网络。通道注意力旨在学习更多的判别性特征,其中 SE 模块就是一种经典的通道注意

力方法,它通过寻找通道之间的相互关系来自适应地改变通道特征响应。相比于传统的神经网络,加入了 SE 注意力机制的 Resnet50 模型大大减少了计算量。空间注意力旨在了解更多细节特征,其中空间变换器网络(STN)允许对数据进行空间操作,

通过对数据进行处理,增强模型的几何不变性,它可以插入到任何现有的卷积架构中,并且只需要进行很少的修改。

注意力机制<sup>[10]</sup>帮助模型为输入( $X$ )的不同部分赋予不同的权重,可提取出更多关键和更具区分性的信息,使模型具有更高的精度,但不会给模型带来额外的计算和存储。注意力机制按照关注点大致可以分为软注意力和硬注意力两种。软注意力更注重通道和空间,且软注意力是确定性的。它利用模型计算梯度进行正向传播和反向更新并学习模型权重,通过训练直接生成权重。硬注意力更倾向于随机预测,更关注离散的位置信息,强调模型的动态变化。因此,硬注意力很难采用端到端的训练方法,多是通过强化学习来实现。

本文采用的是软注意力<sup>[11]</sup>。

### 2.2.1 注意力机制原理及公式

通道注意力<sup>[12]</sup>可以看作是一个计算单元,可在卷积网络的输出特征中为每个通道增加相应的权重,使得神经网络更加关注能够提高分类精度的通道。具体来说,为了有效地计算通道权重,通过卷积操作  $F_{tr}$  来获取输入图像,通过池化操作来获得标记为  $U=[u_1, u_2, \dots, u_a]$  的特征图,其大小为  $H \times W \times a$ ,其中  $F_{tr}$  为常规卷积操作,  $u_a$  为第  $a$  个特征图,  $H$  为特征图的高,  $W$  为特征图的宽,  $a$  为特征通道数。然后用函数  $F_{sq}$  和  $F_{ec}$  计算  $U$  的通道权重。其中,  $F_{sq}$  操作为压缩(squeeze)操作,使用全局平均池化操作、 $F_{tr}$  产生的通道、ReLU<sup>[13]</sup> 激活函数、注意力模块、两个全连接层以及 Sigmoid 激活函数,生成了大小为  $1 \times 1 \times a$  的向量;  $F_{ec}$  为激励(Excitation)操作,是两个全连接层(FC)构成的瓶颈结构,可防止过拟合,从而提高了泛化能力。最后通过函数  $F_{scale}$  得到通道注意力<sup>[12]</sup>特征图:

$$\tilde{X} = F_{scale}(u_a, s_a) = u_a \times s_a, \quad (1)$$

式中:  $\tilde{X}$  为通道注意力特征图;  $s_a$  为  $a$  通道的权重;  $u_a$  为  $a$  通道的特征图。

将这些加权特征映射到训练网络中,可以使分

类器更加关注对图像分类结果有帮助的信息,而忽略或弱化不相关的信息。

### 2.2.2 注意力机制在模型中的应用

注意力机制可以提高网络对自己感兴趣区域的提取能力,同时可以提升网络的识别精度。本文在 ResNet 经典网络上添加注意力模块,并改进模型参数,最终形成了可识别带钢表面缺陷的网络结构 A-ResNet50 和 A-ResNet101。

基于注意力机制的 ResNet50 和 ResNet101 的核心就是图 1 所示模型虚线框内的注意力层、全连接层以及 Softmax 分类层。包含注意力模块的网络具有更强大的特征提取能力,且 ResNet 网络层数和深度的优势使其分类效果更加显著。

### 2.3 迁移学习

迁移学习<sup>[14]</sup> 通过从相关领域的中提取有利信息,解决了跨领域学习问题。更重要的是,通过解决训练数据有限的情况,迁移学习可以极大地提高学习性能,避免网络数据过度拟合。近年来,迁移学习技术已被广泛应用于模式识别中,例如细粒度识别、图像识别和图像分类任务<sup>[15]</sup>。

2014 年, Donahue 等<sup>[16]</sup> 使用大型数据库训练卷积神经网络,与使用简单线性分类器相比,该卷积神经网络可以自主学习特征,具有足够的泛化能力。因此,本文利用源数据训练出的模型来提取图片特征,再冻结已训练模型中的所有特征提取层的参数,仅替换后面的全连接层,最后调整模型的输出层,以适应带钢表面缺陷识别和分类的任务。这种传递技术基于参数的传递,保留了预训练模型出色的特征提取能力,与传统的复杂多核学习技术相比,具有更高的识别精度和泛化能力。

## 3 材料与方法

### 3.1 数据集

本文以六种不同种类的带钢表面缺陷图像作为研究对象,如图 2 所示。本实验数据集共采用原始灰度图像 1800 张<sup>[17]</sup>,分辨率大小为 200 pixel ×




图 2 带钢表面缺陷数据集。(a) Cr; (b) In; (c) Pa; (d) Ps; (e) Rs; (f) Sc

Fig. 2 Strip surface defect dataset. (a) Cr; (b) In; (c) Pa; (d) Ps; (e) Rs; (f) Sc



200 pixel,其中氧化铁皮(Rs)300张,裂纹(Cr)300张,夹杂物(In)300张,乳化液斑迹(Pa)300张,麻点(Ps)300张,划痕(Sc)300张。这6类图片分别被放置在不同文件夹中,且标上标签,标签0代表裂纹,标签1代表夹杂物,标签2代表乳化液斑迹,标签3代表麻点,标签4代表氧化铁皮,标签5代表划痕。迁移学习使用的是Imagenet数据集里的金属图集。本文将收集好的数据集图片尺寸统一缩放至224 pixel×224 pixel,然后再进行模型的训练。

### 3.2 图像增强

#### 3.2.1 图像预处理

由于深度残差网络含有大量的参数,因此存在过拟合的风险。在小样本的条件下,数据集的训练样本不足成了当前首要解决的问题,最直接的方法就是增加数据训练样本。为了提高网络模型的鲁棒性并减少过拟合,需采用数据增强策略来扩大训练数据集。首先从采集的图像中随机选择80%用于训练,20%用于测试,然后把预训练数据集中的图片进行翻转镜像和旋转变换操作,再增加高斯噪声,把训练图像集扩充到5400幅,作为扩充的训练数据集,如表1所示。最后采用双线性差值法把图像尺寸缩放为224 pixel×224 pixel。数据预处理操作如图3所示。

表1 带钢表面缺陷数据集分布表

Table 1 Distribution of strip surface defect datasets

Type of defects	Cr	In	Pa	Ps	Rs	Sc
Before expansion	300	300	300	300	300	300
After expansion	900	900	900	900	900	900

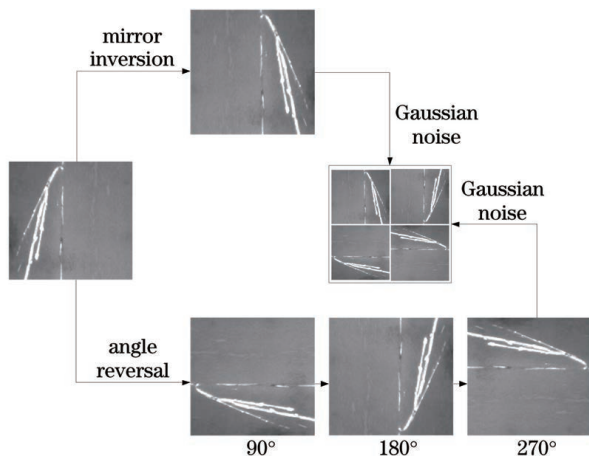


图3 数据预处理操作

Fig. 3 Data preprocessing

#### 3.2.2 伪彩色图像增强

为了实现带钢表面缺陷识别,本文引入了图像的数据增强,在扩充数据集样本数量的同时,还改善了图像的视觉效果,使得样本图像的特征更易被提取。常见的图像增强方法包括灰度变换、直方图处理、空间滤波和伪彩色图像处理等。本文采用了伪彩色图像增强的方法。

密度分割法又称灰度分割法<sup>[18]</sup>,是伪彩色图像增强中比较常见的方法。其原理就是将图像不同灰度级*i*分给不同的区间以制定彩色 $C_i$ ,这样就形成了一幅经伪彩色处理过的图像。假设 $[0, K]$ 为原始灰度图像的灰度级,将灰度级分为*L*段,则图像分为 $I_0, I_1, \dots, I_i, \dots, I_L$ ,其中 $I_0=0$ 代表黑色图像, $I_L=K$ 代表白色图像。将每一段灰度映射成一种彩色:

$$\begin{cases} g(x, y) = C_i \\ I_{i-1} \leq f(x, y) \leq I_i \end{cases}, \quad (2)$$

式中: $g(x, y)$ 为输出的伪彩色图像; $C_i$ 为灰度值在 $[I_{i-1}, I_i]$ 区间内所对应的颜色; $f(x, y)$ 为原图像。

伪彩色增强效果如图4所示。




图4 伪彩色增强效果。(a)增强前;(b)增强后

Fig. 4 False color enhancement effect. (a) Before enhancement; (b) after enhancement

### 3.3 损失函数

神经网络中的损失函数有很多,在不同情况下使用不同的损失函数可以使模型学习到更多的特征。若损失函数很小,表明机器学习模型训练出来的结果与数据真实分布很接近,则模型性能良好;若损失函数很大,表明机器学习模型训练出来的结果与数据真实分布差别较大,则模型性能不佳。本文选取 Softmax Loss 损失函数:

$$S_k = \frac{\exp(a_k)}{\sum_{k=1}^T \exp(a_k)}, \quad (3)$$

式中: $S_k$ 为 Softmax Loss 损失函数的输出; $a_k$ 为经过前序网络到达 softmax 层的  $T \times 1$  向量中的第  $k$  个元素; $T$ 为类别个数。对应的 Softmax Loss 函

数输出为

$$L = -\lg S_k = -\lg \frac{\exp(a_k)}{\sum_{k=1}^T \exp(a_k)} = -a_k + \lg \sum_{k=1}^T \exp(a_k) \quad (4)$$

Softmax Loss 的曲线如图 5 所示。Softmax Loss 损失函数受异常点的干扰较小,故本文使用 Softmax Loss 损失函数。




图 5 Softmax Loss 曲线图

Fig. 5 Softmax Loss curve

## 4 实验与结果分析

本文在不同学习率下对模型的收敛速度进行了实验对比,并研究了不同信噪比对模型的影响和注意力机制对模型的影响。

### 4.1 实验环境

该实验的硬件配置选用的是 i7-9700K/GeForce, 显卡为 RTX2060, 操作系统为 Ubuntu16.01, 开发平台是 Tensorflow。

### 4.2 模型准备与超参数设置

首先搭建好 AlexNet, ResNet 和 GoogleNet 网络, 载入预训练好的 AlexNet, ResNet50, ResNet101 和 GoogleNet 模型的权重文件, 将特征提取层冻结, 去除掉原始网络的全局平均池化层和 FC 层, 在基本的模型中嵌入通道注意力模块层, 使得特征获得不同的权重, 然后添加新的全局平均池化层和 FC 层以便于后续模型的训练。作为本次迁移学习的预训练模型, 在训练之前需要设置一些参数, 例如学习率设置为 0.01~0.00001, 实验之后选取 0.001 作为最终的学习率。另外一个超参数是失活率(Drop\_out), 经过交叉验证之后, 选取失活率为 50% 的模型, 其收敛效果最好。Softmax 分类个数设置为 6, 满足本文六种带钢表面缺陷种类的识别分类任务。为了更加方便地查看模型训练过程, 在训练过程中, 每隔 10 个轮次(epoch)设立一个检查

点, 对验证集中的数据进行验证, 输出验证准确率, 最后保存精度最高的模型。

### 4.3 实验评价准则

本文采用平均准确率、精准率、召回率和  $F_1$  评价指标评价模型分类的结果。平均准确率定义为

$$\bar{A} = \frac{1}{n_b} \sum_{a'=1}^{n_b} \frac{n_{a'a'}}{n_{a'}} \quad (5)$$

式中:  $n_b$  为样本类别总数, 本文取 6;  $a'$  为类别标签;  $n_{a'}$  为类别标签为  $a'$  的样本总数;  $n_{a'a'}$  为类别标签为  $a'$  的样本被正确预测为第  $a'$  类样本的总数。精准率和召回率的计算公式分别为

$$P_{pr} = \frac{T_p}{T_p + F_p} \quad (6)$$

$$P_{rc} = \frac{T_p}{T_p + F_n} \quad (7)$$

式中:  $P_{pr}$  为精准率;  $P_{rc}$  为召回率;  $T_p$  为样本为正类且预测为正类的样本数量;  $F_p$  为样本为负类但预测为正类的样本数量;  $F_n$  为样本为正类但预测为负类的样本数量。结合精准率和召回率, 得出  $F_1$  的计算公式为

$$F_1 = \frac{2 \cdot P_{pr} \cdot P_{rc}}{P_{pr} + P_{rc}} \quad (8)$$

### 4.4 不同学习率对模型性能的影响

影响模型过拟合的不仅仅是样本的数据量, 学习率也是一个非常重要的超参数, 它表示模型权重更新的速率, 设置过大即代价函数波动太大, 实验结果不够准确; 设置过小则网络模型收敛效果不理想, 导致训练时间增加。本文基于 A-ResNet 网络模型, 将学习率分别设置为 0.01、0.001、0.0001、0.00001 并进行分析。

图 6 为不同学习率下模型的训练集准确率和损失函数的曲线变化。由图 6 可知, 不同的学习率对模型的影响是有区别的。在学习率为 0.00001 的条件下, 当模型的训练轮数增加至 100 时, 准确率仍未达到拟合状态, 且损失值下降的速度很慢。当学习率为 0.0001 时, 准确率刚开始降低, 随着训练轮数的增加, 逐渐趋于稳定, 损失函数曲线也较为平滑。当学习率为 0.01 时, 准确率曲线收敛较快, 但是损失函数曲线不稳定, 随着训练轮数的增加, 损失函数曲线的波动幅度相对前几轮波动较大, 无法趋于稳定状态。当学习率为 0.001 时, 准确率曲线与损失函数曲线的变化相比于其他三种情况更平滑, 更适应这个迁移学习的模型。为了验证不同学习率对模型性能的影响, 表 2 列出了不同学习率下不同缺陷




图 6 不同学习率下模型的训练曲线。(a)准确率曲线;(b)损失函数曲线

Fig. 6 Training curves of model under different learning rates. (a) Accuracy curves; (b) loss function curves

表 2 不同学习率下各个缺陷的识别准确率

Table 2 Recognition accuracy of each defect under different learning rates

Learning rate	Recognition accuracy / %						Training accuracy / %	Training loss value	Average accuracy / %
	Cr	In	Pa	Ps	Rs	Sc			
0.01	100	95.00	100	85.00	100	98.33	99.24	0.0986	96.32
0.001	100	98.33	100	96.67	98.33	98.33	<b>99.31</b>	<b>0.0205</b>	<b>98.61</b>
0.0001	90.00	98.33	100	88.33	100	98.33	95.58	0.1154	95.83
0.00001	98.33	96.67	100	78.33	100	96.67	81.74	0.5037	95.00

检测的准确率,可以看出,当学习率为 0.001 时,训练集的准确率达到 99.31%,且损失值为 0.0205,这表明 0.001 的学习率对这个模型的亲和力较好,检测性能最优。相比于其他三种学习率设定,0.001 的学习率更能够保证此模型的高精度识别,因此在后续的实验中选取 0.001 作为最佳学

习率。

#### 4.5 不同高斯信噪比对模型的影响

本文采用的数据集存在光照不均匀和纹理差异较大等现象,为了更客观地评价模型的鲁棒性,在测试集划痕的图片中加入了高斯白噪声,信噪比分别为 20 dB,30 dB,40 dB,50 dB,如图 7 所示。




图 7 具有不同信噪比的图片。(a)无噪声;(b) 50 dB;(c) 40 dB;(d) 30 dB;(e) 20 dB

Fig. 7 Pictures with different signal-to-noise ratios. (a) No noise; (b) 50 dB; (c) 40 dB; (d) 30 dB; (e) 20 dB

图 7 为加入不同信噪比高斯白噪声的缺陷放大图像,可以直观看出不同信噪比下的噪声覆盖程度。陈小芳等<sup>[7]</sup>为了验证改进 MB-LBP 算法的抗噪能力,采用不同模型在不同信噪比下进行实验,实验结果如表 3 所示。由表 3 可知,改进的 MB-LBP 算法相对于 LBP 和 MB-LBP,在测试集上的识别准确率有所提升。只进行迁移学习的 ResNet50 模型在 50 dB 信噪比下的识别准确率只有 95.56%,加入了注意力机制的 ResNet50 模型在不同信噪比下的识

别准确率都有所提升,在 20 dB,30 dB,40 dB 信噪比下较改进 MB-LBP 算法分别提高了 3.81,9.77,1.61 个百分点。而当信噪比为 40 dB 时,本文所提算法的识别准确率却低于改进 MB-LBP 算法 1.22 个百分点。这是由于高斯白噪声的随机性,噪声点落在图片上的位置不同,从而细节丢失,图像特征无法全面识别,精度偏低。经多次实验发现,在 40 dB 的情况下,本文所提方法相较传统机器学习方法仍能取得不错的识别准确率。由于信噪比的减



表 3 不同信噪比高斯噪声下不同模型的抗噪能力  
Table 3 Anti-noise ability of each model under Gaussian noise with different signal-to-noise ratios

Model	Recognition accuracy / %			
	20 dB	30 dB	40 dB	50 dB
LBP <sup>[7]</sup>	22.78	63.57	69.26	75.05
MB-LBP <sup>[7]</sup>	25.76	71.35	90.24	91.83
Improved MB-LBP <sup>[7]</sup>	30.63	78.56	<b>95.66</b>	97.00
ResNet50	21.65	75.56	92.22	95.56
A-ResNet50	<b>34.44</b>	<b>88.33</b>	94.44	<b>98.61</b>

小, 图片中的噪声点增多, 识别精度降低, 无法满足正常识别要求, 在信噪比大于等于 30 dB 时识别分类效果较好, 故本文所提模型具有一定的抗噪能力。

为了验证本文所提模型对不同缺陷的识别精度, 利用 50 dB 信噪比下带钢表面缺陷数据集样本对 6 类不同缺陷进行实验, 得出的精准率、召回率和  $F_1$  值如表 4 所示。由表 4 可知, 本文所提模型可以

表 4 所提模型 A-ResNet50 的识别能力  
Table 4 Recognition ability of proposed model A-ResNet50

Defect category	Number of samples						$P_{pr}$	Recall rate	$F_1$
	Cr	In	Pa	Ps	Rs	Sc			
Cr	60	0	0	0	0	0	1.000	1.000	1.000
In	0	59	0	0	1	1	0.967	0.983	0.975
Pa	0	0	60	2	0	0	0.968	1.000	0.984
Ps	0	1	0	58	0	0	0.983	0.967	0.975
Rs	0	0	0	0	59	0	1.000	0.983	0.992
Sc	0	0	0	0	0	59	1.000	0.983	0.992

有效地完成带钢表面缺陷分类工作, 6 种类别缺陷

下的精准率、召回率以及  $F_1$  值均在 0.967 之上, 深度神经网络在底层提取图像的低级特征, 再在深层生成高级语义特征, 从而实现了缺陷图像的高准确率识别。

#### 4.6 注意力机制对模型的影响

为了验证本文所提网络模型的有效性, 在伪彩色图像增强后的相同数据集上进行比较实验。实验选用目前在深度学习中应用很广的三种网络模型, AlexNet、GoogleNet 和 ResNet, 以及其改进的 A-AlexNet、A-GoogleNet 和 A-ResNet 网络模型。AlexNet 通过引入 ReLU, 可以模拟数据的稀疏性, 以最大近似的方式保留数据的特征, 从而加速收敛。GoogleNet 将全连接甚至卷积中的局部连接全部替换为稀疏连接, 既能保持网络结构的稀疏性, 又能利用密集计算的高效性。

##### 4.6.1 五折交叉验证

为了验证注意力机制对各个缺陷种类的影响, 绘制了图 8 所示的混淆矩阵。测试采用五折交叉验证法, 共测试了 5 次, 以找到使得模型泛化性能最优的超参值。由图 8 可以更清晰更直观地看到各个缺陷类别之间特征的相似性和混淆性, 也可以看到网络模型更擅长提取什么样的底层特征。图 8(a) 是未加入注意力机制的 ResNet50 网络, 可以看出, 网络在 Cr、Ps 分类任务上效果非常不佳, 其余的较正常, 原因是 Cr、Ps 的底层特征很相似, 网络无法有效地区分它们, 从而导致错误的分类。而图 8(b) 是加入了注意力机制的 ResNet50 网络, 分类效果优秀。通道注意力旨在学习更多的判别性特征, 它通过寻找通道之间的相互关系来自适应地改变通道特征响应。相比于传统的神经网络, 本文所提模型大大增加了特征提取能力, 分类准确率得到提高。

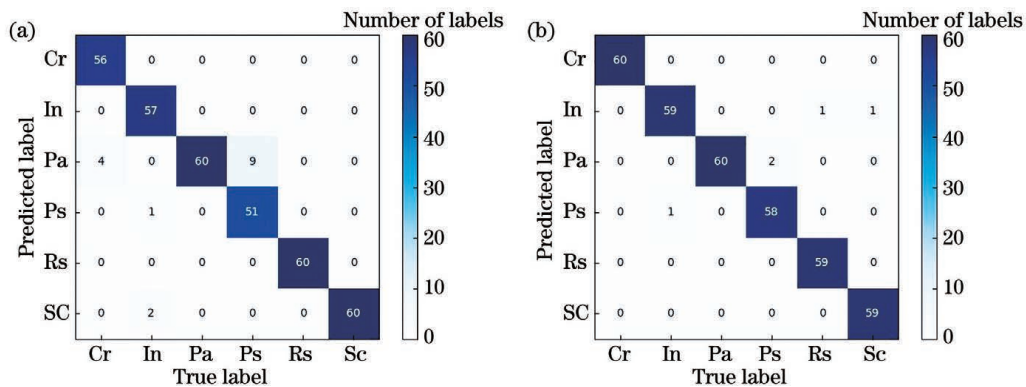


图 8 不同模型的混淆矩阵。(a) ResNet50 ;(b) A-ResNet50

Fig. 8 Confusion matrix of each model. (a) ResNet50; (b) A-ResNet50

## 4.6.2 不同网络对比实验

在相同的实验环境下,分别对三种预训练模型进行迁移学习,并且与加入了注意力机制的网络以及传统机器学习方法进行比较,测试准确率如表 5 所示。可以看出,对于 Ps 缺陷,AlexNet 网络的识别准确率只有 75.00%,平均准确率为 95.28%,加入了注意力机制的 A-AlexNet 网络相较 AlexNet 网络,识别准确率提升了 10 个百分点,平均识别准确率提升了 1.09 个百分点;GoogleNet 网络在 Cr 和 Ps 的分类任务上效果不佳,在引入了注意力机制之后,Cr 和 Ps 的识别准确率分别提升了 11.66 个百分点和 8.33 个百分点,效果显著。ResNet50 和 ResNet101 是两种不同深度的网络,基于注意力机制的 A-ResNet50 的平均识别准确率优于其他三种模型 AlexNet, GoogleNet,

Resnet101,达到了 98.61%的准确率,对 6 种缺陷的识别都有很好的效果。相较于文献[5]和文献[7]中模型的准确率,所提方法分别提高了 2.44 个百分点和 1.61 个百分点,带钢表面缺陷的识别准确率得到了提高。结果表明,A-ResNet50 和 A-ResNet101 的平均准确率相差不大,但是考虑到模型尺寸的大小以及所占用的内存空间,A-ResNet50 最优;从测试单位推断时间来看,A-ResNet101 的识别速度是 7.73 /s,A-ResNet50 的识别速度是 12.76 /s,后者是前者的 1.65 倍,表明所提模型可以实现带钢表面缺陷识别的实时性。综合考虑准确率、单位推断时间以及模型的大小,A-ResNet50 模型优于对照实验中的其他模型,表明该模型可以有效且高精度地完成带钢表面缺陷的分类识别工作。

表 5 不同模型对带钢表面缺陷的识别结果

Table 5 Recognition results of strip steel surface defects by different models

Model	Recognition accuracy /%						Average accuracy /%	Unit inference time /s
	Cr	In	Pa	Ps	Rs	Sc		
Model in Ref. [5]	97.00	94.00	98.00	98.00	97.00	93.00	96.17	0.065
Model in Ref. [7]	99.00	98.00	97.00	96.00	97.00	95.00	97.00	0.058
AlexNet	100	98.33	100	75.00	100	98.33	95.28	0.016
A-AlexNet	100	95.00	100	85.00	100	98.33	96.39	0.017
GoogleNet	81.67	100	91.67	81.67	90.00	98.33	90.56	0.389
A-GoogleNet	93.33	100	96.67	90.00	90.00	100	95.00	0.041
ResNet50	93.33	95.00	100	85.00	100	100	95.56	0.074
A-ResNet50	100	98.33	100	96.67	98.33	98.33	<b>98.61</b>	0.078
ResNet101	100	98.33	100	88.33	98.33	100	97.50	0.121
A-ResNet101	100	96.67	100	91.67	100	100	98.05	0.130

## 5 结 论

针对带钢表面缺陷识别问题,提出了基于注意力机制的改进方法。首先使用迁移学习的方法对图像特征进行提取,利用注意力模块使得特征有了其相应的权重,再通过伪彩色图像增强处理方法进行数据增强操作,图像特征更易被提取。通过多组对比实验发现,所提方法在不同信噪比下,对带钢表面缺陷的识别都有着良好的效果,且具有一定的抗噪性。在识别准确率和单位推断时间上,所提方法的识别效果都要优于传统方法,这对于工业智能分检问题中卷积神经网络的使用具有重要意义。

## 参 考 文 献

- [1] Wang Y P. The principle and technology of plate and strip production[M]. Beijing: Metallurgical Industry Press, 1995: 3-5.  
王延涛. 板带材生产原理与工艺[M]. 北京: 冶金工业出版社, 1995: 3-5.
- [2] Li D, Bai G J, Jin Y Y, et al. Machine-vision based defect detection algorithm for packaging bags [J]. Laser & Optoelectronics Progress, 2019, 56(9): 091501.  
李丹, 白国君, 金媛媛, 等. 基于机器视觉的包装袋缺陷检测算法研究与应用[J]. 激光与光电子学进展, 2019, 56(9): 091501.



- [3] Hu L T. Research on surface defect recognition of steel plate based on machine vision [D]. Wuhan: Wuhan University of Science and Technology, 2018. 胡联亨. 基于机器视觉的钢板表面缺陷识别研究 [D]. 武汉: 武汉科技大学, 2018.
- [4] Guo H, Xu W, Liu Y F. Steel plate surface defect recognition based on support vector machine [J]. Journal of Donghua University (Natural Science), 2018, 44(4): 635-639. 郭慧, 徐威, 刘亚菲. 基于支持向量机的钢板表面缺陷检测 [J]. 东华大学学报(自然科学版), 2018, 44(4): 635-639.
- [5] Shan D R, Tong C, Nai X S, et al. Recognition of surface defects on strip based on wavelet and gray levelco-occurrence matrix [J]. Manufacturing Technology & Machine Tool, 2020(2): 120-123. 单东日, 童灿, 乃学尚, 等. 基于小波和灰度共生矩阵的带钢表面缺陷识别 [J]. 制造技术与机床, 2020(2): 120-123.
- [6] Chang J, Guan S Q, Shi H Y, et al. Strip defect classification based on the improved generative adversarial networks and MobileNetV3 [J]. Laser & Optoelectronics Progress, 2021, 58(4): 0410016. 常江, 管声启, 师红宇, 等. 基于改进生成对抗网络和 MobileNetV3 的带钢缺陷分类 [J]. 激光与光电子学进展, 2021, 58(4): 0410016.
- [7] Chen X F, Yu F Q, Chen Y. Application of improved MB-LBP features and LPP algorithm in strip surface defect identification [J]. Transducer and Microsystem Technologies, 2020, 39(4): 156-160. 陈小芳, 于凤芹, 陈莹. 改进 MB-LBP 特征与 LPP 算法在带钢表面缺陷识别上的应用 [J]. 传感器与微系统, 2020, 39(4): 156-160.
- [8] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [9] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 7132-7141.
- [10] Xu W H, Pei Y J, Gao D L, et al. Mass classification of breast mammogram based on attention mechanism and transfer learning [J]. Laser & Optoelectronics Progress, 2021, 58(4): 0410007. 许文慧, 裴以建, 郜冬林, 等. 基于注意力机制与迁移学习的乳腺钼靶肿块分类 [J]. 激光与光电子学进展, 2021, 58(4): 0410007.
- [11] Pu X F, Ning Q, Lei Y J, et al. Identification of agricultural plant diseases based on binarized convolutional neural network [J]. Journal of Chinese Agricultural Mechanization, 2020, 41(2): 177-182. 蒲秀夫, 宁芊, 雷印杰, 等. 基于二值化卷积神经网络的农业病虫害识别 [J]. 中国农机化学报, 2020, 41(2): 177-182.
- [12] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need [C]//Advances in neural information processing systems, December 4-9, 2017, Long Beach, CA, USA. Canada: NIPS, 2017: 5998-6008.
- [13] Nair V, Hinton G E. Rectified linear units improve restricted boltzmann machines [C]//In Proceedings of the 27th International Conference on Machine Learning (ICML-10), June 21, 2010, Madison, WI, United States. Madison: Omnipress, 2010: 807-814.
- [14] Pan S J, Yang Q. A survey on transfer learning [J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [15] Shao L, Zhu F, Li X L. Transfer learning for visual categorization: a survey [J]. IEEE Transactions on Neural Networks and Learning Systems, 2015, 26(5): 1019-1034.
- [16] Donahue J, Jia Y Q, Vinyals O, et al. DeCAF: a deep convolutional activation feature for generic visual recognition [C]//Proceedings of the 31st International Conference on Machine Learning, June 21, 2014, Beijing, China. Beijing: JMLR, 2014, 32: 647-655.
- [17] Song K C, Yan Y H. A noise robust method based on completed local binary patterns for hot-rolled steel strip surface defects [J]. Applied Surface Science, 2013, 285: 858-864.
- [18] Liu W. Analysis and realization of medical images pseudo color based on the regional segmentation [J]. Journal of Minzu University of China (Natural Sciences Edition), 2019, 28(3): 61-64. 刘伟. 基于区域分割的伪彩色医学影像图像分析及实现 [J]. 中央民族大学学报(自然科学版), 2019, 28(3): 61-64.