

王前, 包春梅, 陈望, 等. 基于多尺度特征聚合的铝材表面缺陷分类[J]. 智能计算机与应用, 2024, 14(11): 124-130. DOI: 10.20169/j.issn.2095-2163.241119

基于多尺度特征聚合的铝材表面缺陷分类

王前^{1,2}, 包春梅^{1,2}, 陈望^{1,2}, 李志玲^{1,2}, 王林²

(1 贵州民族大学 数据科学与信息工程学院, 贵阳 550025;

2 贵州民族大学 贵州省模式识别与智能系统重点实验室, 贵阳 550025)

摘要: 针对铝材表面缺陷不明显和缺陷尺度差异大导致缺陷类别难以识别的问题, 提出了一种多尺度特征聚合的分类方法。首先, 使用改进的 CutMix 数据增强对缺陷样本数据进行离线扩充和引入多类别 *FocalLoss* 损失函数对各类别进行加权。其次, 使用多尺度特征聚合方法加强浅层特征与深层特征的信息交互融合, 进而加强模型对浅层特征的关注度。最后, 通过 GAM 注意力机制加强全局特征信息的关注度。实验表明, 多尺度特征聚合的分类方法对铝材缺陷样本分类的精准率、召回率、特异性和准确率分别为 95.4%、96.1%、99.6% 和 96.4%, 相较于 ResNet 的分类准确率、召回率和特异性等均有明显提升, 说明该方法在铝材表面缺陷分类任务中具有较好的性能。为在工业上实现铝材表面缺陷的自动化分类提供了一种可靠方案。

关键词: 缺陷分类; 多尺度特征聚合; GAM 注意力机制; *FocalLoss*

中图分类号: TP391.4 文献标志码: A 文章编号: 2095-2163(2024)11-0124-07

Aluminum surface defect classification based on multi-scale feature aggregation

WANG Qian^{1,2}, BAO Chunmei^{1,2}, CHEN Wang^{1,2}, LI Zhiling^{1,2}, WANG Lin²

(1 School of Data Science and Information Engineering, Guizhou Minzu University, Guiyang 550025, China; 2 Key Laboratory of Pattern Recognition and Intelligent System of Guizhou Province, Guizhou Minzu University, Guiyang 550025, China)

Abstract: A multi-scale feature aggregation classification method is proposed to solve the problem that the surface defects of aluminum are not obvious, and the size difference of defects is large. Firstly, the improved CutMix data enhancement is used to expand the defect sample data offline and the multi-class *FocalLoss* function is introduced to weight the various categories. Secondly, the multi-scale feature aggregation method is used to strengthen the information interaction and fusion of shallow features and deep features, and then enhance the model's attention to shallow features. Finally, the attention of global feature information is enhanced by GAM attention mechanism. The experiment shows that the precision, recall rate, specificity and accuracy of the classification of aluminum defect samples by multi-scale feature aggregation are 95.4%, 96.1%, 99.6% and 96.4%, respectively, which are significantly improved compared with the classification accuracy, recall rate and specificity of ResNet. It demonstrates that this method has good performance in the task of aluminum surface defect classification. The research provides a reliable scheme for the automatic classification of aluminum surface defects in industry.

Key words: defect classification; multi-scale feature aggregation; GAM attention mechanism; *FocalLoss*

0 引言

近年来,随着工业的快速发展和人们对产品质量要求的日益提高,表面缺陷检测在工业实践中发

挥着至关重要的作用。表面缺陷检测能够帮助企业及时发现产品表面的缺陷,从而提高产品质量和生产效率,增强产品在市场上的竞争力。快速且准确识别产品表面缺陷对工业产品生产的快速发展具有

基金项目: 贵州省科技计划项目(黔科合基础-ZK[2022]一般 195,黔科合基础-ZK[2023]一般 143,黔科合平台人才-ZCKJ[2021]007); 贵州省青年科技人才成长项目((黔教合 KY 字[2021]104); 贵州省教育厅自然科学研究项目(黔教技[2023]012号,黔教技[2022]015号,黔教技[2023]061号); 贵州省模式识别与智能系统重点实验室开放课题(GZMUKL[2022]KF01, GZMUKL[2022]KF05); 贵州民族大学基金科研项目(GZMUZK[2023]YB14), 黔教技[2024]063号)。

作者简介: 王前(1997—),男,硕士研究生,主要研究方向:工业缺陷检测;包春梅(1998—),女,硕士研究生,主要研究方向:小样本图像分类;陈望(2000—),男,硕士研究生,主要研究方向:小样本图像分类;李志玲(2000—),女,硕士研究生,主要研究方向:多元域自适应。

通信作者: 王林(1965—),男,教授,主要研究方向:图像处理与机器视觉。Email: wanglin@gzmu.edu.cn。

收稿日期: 2024-07-14

哈尔滨工业大学主办 ◆ 专题设计与应用

重要意义^[1-2]。

传统机器学习方法主要通过表面缺陷产品进行区域选择、组合特征提取和背景纹理建模等^[3]。例如, Jia 等学者^[4]基于支持向量机自动学习复杂的缺陷模式提出了智能实时视觉系统,实现了对钢材表面缺陷的快速检测。Zhang 等学者^[5]通过设计多类支持向量机的强反射金属表面缺陷视觉检测系统,实现了对 7 类金属表面缺陷的高效识别。梁丽媛等学者^[6]利用薄膜触觉传感器采集麻将牌面的纹理特征,并使用支持向量机实现了对麻将纹理的识别。Hu 等学者^[7]提出混合染色体遗传算法用于带钢图像表面缺陷的实时分类研究,实现了带钢图像表面缺陷的快速分类。

随着计算机视觉和深度学习的不断发展,基于深度学习的表面缺陷检测方法已经逐渐成为表面缺陷检测的主要方法^[8]。目前,大量的研究人员通过深度学习方法实现对工业产品表面缺陷的识别。例如,熊政等学者^[9]通过改进 MobileNetV3^[10] 算法以及 Mish 激活函数,使模型对热轧钢带表面缺陷的分类准确率达到 99.44%。翁佩纯等学者^[11]针对称重传感器上应变片焊接缺陷问题,基于 ResNet50 构建了一种焊接缺陷分类模型,实现对应变片焊接缺陷的分类识别。He 等学者^[12]使用生成对抗网络生成带钢表面缺陷样本,解决了深度学习在做模型训练时训练样本不足的问题。

为解决铝材表面缺陷特征不明显和缺陷尺度差异大导致缺陷类别难以识别和深度学习在训练时出现的缺陷训练样本不足的问题,本文基于 ResNet^[13] 设计了多尺度特征聚合方法 (Multi-Scale Feature Aggregation And Fusion Method, MSFAF)。多尺度特征聚合将 ResNet 网络提取的不同层的特征进行融合,融合的特征信息通过全局注意力机制^[14] (Global Attention Mechanism, GAM) 加强全局特征信息。多尺度特征聚合方法能够有效加强浅层特征与深层特征的信息交互融合,进而提升模型对浅层特征的关注度,减少不明显特征和小尺寸缺陷特征在多次特征提取中的信息丢失。经过多尺度特征聚合方法融合的特征信息,通过 GAM 注意力机制加强全局特征信息的关注度,进而加强模型对大尺寸缺陷特征的分类能力。同时,本文基于 CutMix^[15] 数据增强改进设计了合适的数据增强方法和引用了多类别 FocalLoss^[16] 损失来弥补模型对少样本的缺陷类别关注不足。通过多尺度特征聚合方法加强浅层特征和深层特征的交互融合,进而加强模型的性能。

本文主要有 3 个贡献点:

(1) 为解决缺陷样本不足和类别不平衡的问题,本文使用改进的 CutMix 方法对训练样本进行离线扩充,并使用多类别 FocalLoss 损失函数对少样本进行加权。

(2) 为解决浅层特征信息与深层特征信息融合不充分的问题,设计了多尺度特征聚合方法,加强浅层特征与深层特征的交互融合。

(3) 本文算法性能在铝材表面缺陷样本的分类实验中优于目前主流的分类算法,为工业缺陷分类提供了一种有效方案。

1 主要工作

1.1 数据增强

在工业生产中,铝材缺陷样本数据通常较少,且在深度学习的训练中训练样本少易导致模型的过拟合,难以满足实际的工业检测要求。因此,为解决铝材训练缺陷样本不足的问题,本文使用基于 CutMix 改进的数据增强方法对原始铝材缺陷样本进行增强,增加缺陷训练样本数量。由于铝材缺陷样本背景较为庞杂,因此对所有缺陷样本的前景分布进行分析,得到缺陷样本前景分布详解。通过缺陷样本前景分布情况确定剪切坐标框范围。随机抽取 2 张缺陷样本按照剪切坐标剪切图像并交换剪切图像,获得增强的缺陷样本数据,训练样本由 1 564 张扩充到 2 578 张。通过该方法可以满足深度学习需要大量训练样本数据的要求,同时能够有效提升模型分类精度。

1.2 多尺度特征聚合

为加强浅层特征与深层特征的信息交互融合,本文受到特征金字塔网络^[17] (Feature Pyramid Networks, FPN) 和 Inception^[18] 结构的启发,提出了多尺度特征聚合方法。多尺度特征聚合方法利用多尺度特征加权融合算法 (Multi-Scale Feature Wighted Fusion Algorithm, MSFWF) 聚集融合前 3 层的特征信息,融合的特征信息再与后 2 层的特征信息进行融合。基于 ResNet 改进的多尺度特征聚合的网络结构如图 1 所示。

多尺度特征加权融合算法中,首先聚集 ResNet 网络提取的不同层的特征信息,利用卷积、池化或线性插值的方式将 3 个输入特征图大小对齐到相同的比例,并沿着通道维度进行拼接,加强浅层特征信息与深层特征信息交互。其次,拼接得到的特征利用 4 个卷积核大小不同的深度可分离卷积得到 4 个融合特征信息与拼接的特征信息按空间维度进行相

加,并使用卷积使其进一步融合。最后,融合的特征经 Sigmoid 函数处理后对拼接的特征信息进行加

权,进而加强局部特征与全局特征的关注,其算法流程描述如下。

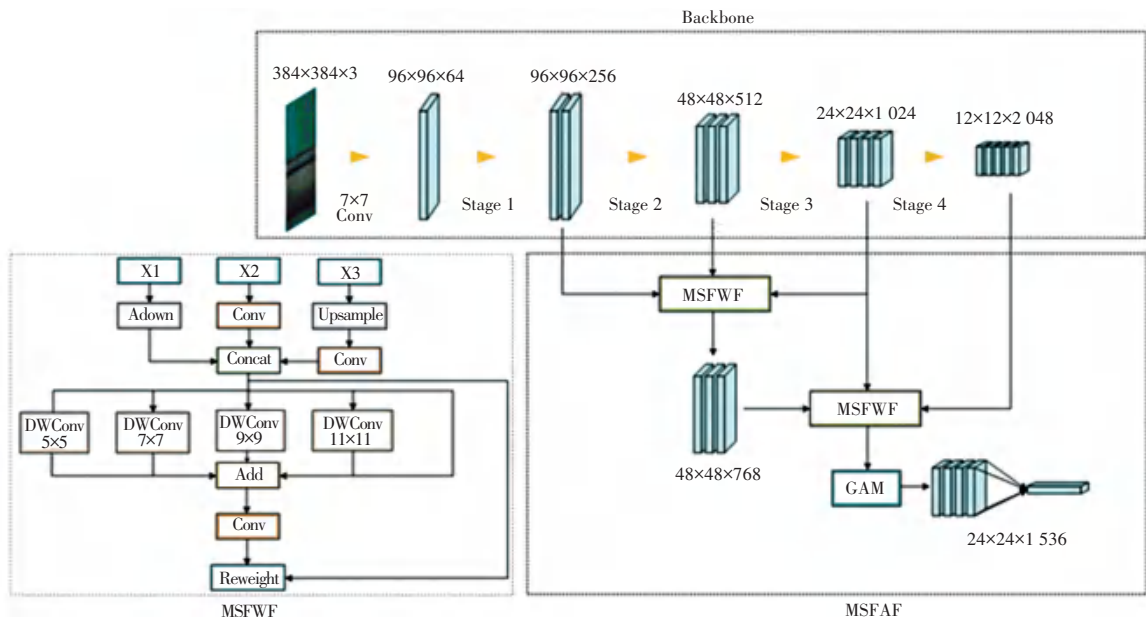


图1 多尺度特征聚合

Fig. 1 Multi-scale feature aggregation fusion

算法1 多尺度特征加权融合算法

1. 输入:特征图 $X_1, X_2, X_3 \in \mathbb{R}^{H \times W \times C}$
2. $\text{def } A\text{Down}(X)$://定义一个下采样方法
3. $X = \text{Avgpool}(X)$ //对输入特征进行平均池化
4. $X_1, X_2 = \text{Split}(X)$ //按通道维度分成两部分
5. $X_1 = \text{Conv}(X_1)$ //卷积融合特征
6. $X_2 = \text{Conv}(\text{MaxPool}(X_2))$ //最大池化后通过卷积融合
7. $X = \text{Concat}(X_1, X_2)$ //按通道维度进行拼接还原
8. $X'_1 = A\text{Down}(X_1), X'_2 = \text{Conv}(X_2), X'_3 = \text{Conv}(\text{Upsample}(X_3))$
9. $X_{\text{Concat}} = \text{Concat}(X'_1, X'_2, X'_3)$ //按通道维度拼接特征
10. $X_{\text{fuse}} = X_{\text{Concat}}$
11. for k in $[5, 7, 9, 11]$://卷积核大小
12. $X_{\text{fuse}} = X_{\text{fuse}} + \text{DwConv}_{k \times k}(X_{\text{fuse}})$ //融合特征信息
13. end for
14. $X_{\text{fuse}} = \text{Sigmoid}(\text{Conv}(X_{\text{fuse}}))$
15. $X_{\text{fuse}} = X_{\text{Concat}} \cdot X_{\text{fuse}}$ //加权拼接的特征信息

1.3 GAM 注意力机制

在铝材表面缺陷分类中,模型提取不同类别之

间的特征信息存在一定的相似性,导致模型通过简单的特征提取难以对样本进行准确分类。因此,本文引入 GAM 注意力机制增强模型对各类别缺陷区域的关注度,进而增强各类别缺陷特征的差异性。GAM 注意力机制由通道注意力子模块和空间注意力子模块构成。其中,通道注意力子模块使用三维排列来保留 3 个维度上的特征信息,然后利用 1 个两层的多感知机 (Multilayer Perceptron, MLP) 来增强特征之间跨维度的空间特征信息交互。空间注意力子模块使用 2 个卷积层融合空间特征信息,进而加强模块对空间特征信息的关注度。GAM 注意力机制的通道注意力子模块和空间注意力子模块,研究推得计算方法如下:

$$F_2 = M_c(F_1) \otimes F_1 \quad (1)$$

$$F_3 = M_s(F_2) \otimes F_2 \quad (2)$$

其中, $F_1 \in \mathbb{R}^{C \times H \times W}$; M_c 和 M_s 分别表示通道注意力和空间注意力;“ \otimes ”表示逐元素乘法; F_2 和 F_3 表示输出特征。GAM 注意力机制的结构示意如图 2 所示。

1.4 多类别 FocalLoss 损失函数

由于模型训练样本类别不平衡,在深度学习的训练中通常会导致模型对缺陷样本关注不足的问题。为解决训练样本类别不平衡的问题,本文使用多类别 FocalLoss 损失函数对训练样本类别进行加

权, 增强模型对训练样本中较少类别的关注度。其中, 本文的多类别 FocalLoss 损失函数的数学表达式为:

$$\text{loss} = -\alpha_c (1 - p_c)^\gamma \log(p_c) \quad (3)$$

$$\alpha_c = \frac{1}{(\text{freq}(c))^\beta} \quad (4)$$

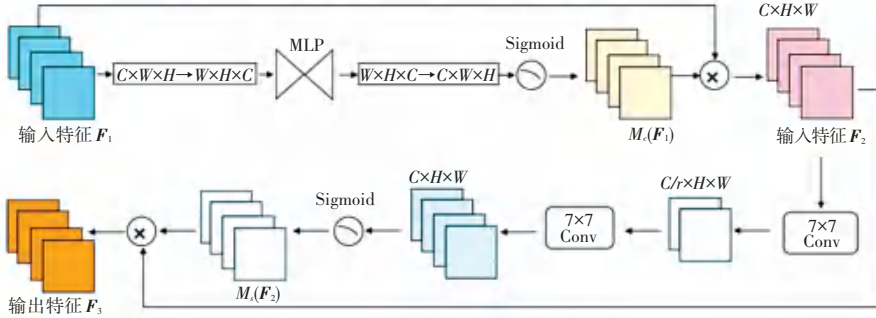


图 2 GAM 注意力机制的网络结构

Fig. 2 Network structure of GAM attention mechanism

2 实验与结果分析

2.1 实验设置及数据

本文模型在 Ubuntu16.04 操作系统下基于 Python 3.8.12 的 Pytorch 2.0.1 版本实现, 显卡 NVIDIA GeForce RTX 3090, CUDA 版本 11.2, 网络模型在更新参数时使用 Adam 优化器, 初始学习率 0.001, batch size 大小为 32, 迭代次数为 120 次。

本文使用 1 955 个分辨率为 2 560×1 920 的铝材表面缺陷样本进行实验, 为防止模型因输入图像分辨率过大导致模型过大, 模型训练时输入图片大小缩放为 384×384。数据集以 8:2 的比例随机划分为训练集和验证集, 训练数据通过改进的 CutMix 方法将训练数据扩充为 2 578 张。

2.2 评估指标

为客观地评估本文算法对铝材缺陷的识别效果, 本文使用精确率 (Precision)、召回率 (Recall)、特异性 (Specificity) 和准确率 (Accuracy) 来评价本文算法的识别效果。其中, 精确率表示识别样本为正样本在所有实际正样本所占比例; 召回率表示在

其中, α_c 表示第 c 个类别权重; p_c 表示 Softmax 输出的第 c 类样本概率值; γ 表示衰减参数; β 表示加权系数。权重的动态修正量的大小由聚焦系数 γ 控制, γ 越大模型通过调整权值缓解类别不平衡现象的作用越强, 但 γ 取值过大时会影响模型在所有类别上的总体分类能力。

实际正样本中被预测为正样本的概率, 召回率越高、漏检概率越低; 特异性表示正确预测负样本占有所有预测为负样本的概率, 特异性越高、误判概率越低。各指标的数学定义可由如下公式进行表示:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (5)$$

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

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

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (8)$$

其中, TP 表示被模型预测为正类的正样本数量; TN 表示被模型预测为负类的负样本数量; FP 表示被模型预测为正类的负样本数量; FN 表示被模型预测为负类的正样本数量。

2.3 消融实验

为验证各模块检测的有效性, 本文在相同的设置下进行了消融实验, 展示各个改进模块在铝材缺陷样本的检测性能, 见表 1。

表 1 消融实验

Table 1 Ablation experiment

算法	P	R	S	Acc
ResNet	0.756	0.858	0.985	0.854
ResNet+ CutMix	0.885	0.919	0.991	0.916
ResNet+CutMix+ MSFAF	0.930	0.930	0.995	0.949
ResNet+CutMix+ MSFAF+ GAM	0.938	0.947	0.995	0.951
ResNet+CutMix+ MSFAF+ GAM+ FocalLoss	0.954	0.961	0.996	0.964

由表 1 分析可知, 首先, 使用改进的 CutMix 数

据增强方法对训练数据进行增强, 对铝材缺陷样本

分类的准确率、召回率、特异性和准确率相较于未使用数据增强的 ResNet 分别提升 12.9%、6.1%、0.6%和 6.2%，提升效果十分明显。这就表明使用改进的 CutMix 数据增强方法能够有效增强缺陷样本数据。其次，在 ResNet 算法中增加一个多尺度特征聚合方法，算法分类的精确率、召回率和准确率大幅提升了 4.5%、1.1%和 3.3%，同时分类的特异性也相应提升 0.4%。由此说明设计的多尺度特征聚合方法能够加强浅层特征与深层特征的交互融合。接着，通过引入 GAM 注意力机制，算法分类的精确率、召回率、特异性和准确率均有一定的提升，也就说明 GAM 注意力机制能够增强重要区域的关注度。最后，通过引入了多类别的 FocalLoss 损失函数，算法分类的准确率、召回率、特异性和准确率分别提升了 1.6%、1.4%、0.1%和 1.3%。说明引入的多类别的 FocalLoss 损失函数，能够有效缓解缺陷样本类别不平衡。

综合来说，使用改进的 CutMix 数据增强后的本文算法与未使用数据增强的基准算法相比，分类算法的精确率、召回率、特异性和准确率分别提升了 19.8%、10.3%、1.1%和 11.0%，对于铝材缺陷样本的分类性能有着较大提升。

2.4 对比试验

为比较本文算法与其他算法的检测性能，在相同数据集和实验环境下与其他算法进行对比实验，实验结果见表 2。

表 2 不同模型实验结果

Table 2 Experimental results of different models

算法	<i>P</i>	<i>R</i>	<i>S</i>	<i>Acc</i>
ResNet ^[13]	0.885	0.919	0.991	0.916
ResNetxt ^[19]	0.909	0.939	0.994	0.940
RepVGG ^[20]	0.919	0.903	0.993	0.927
InceptionV3 ^[18]	0.943	0.940	0.995	0.955
MobileNetV3 ^[10]	0.932	0.917	0.994	0.946
ConvNeXt ^[21]	0.919	0.947	0.993	0.937
本文算法	0.954	0.961	0.996	0.964

对比分类算法的实验数据可知，本文算法的分类精确率、召回率、特异性和准确率分别为 95.4%、96.1%、99.6%和 96.4%，明显优于现有其他算法；较基准算法 ResNet 准确率大幅提升了 4.8%；与主流分类算法 ResNetxt、RepVGG 和 ConvNeXt 相比分类准确率分别高出 2.4%、3.7%和 2.7%；与经典算法 InceptionV3 和 MobileNetV3 相比分别高出 0.9%

和 1.8%。本文算法通过改进 ResNet 算法大幅提升了铝材缺陷样本的分类准确率，为工业实现铝材缺陷分类提供了一种可靠的方案。

为比较本文算法和基准算法对各类缺陷的分类准确率，本文在相同的实验环境与实验样本数据下测试了基准算法与本文算法对各类缺陷的分类准确率，检测结果见表 3。

表 3 基准算法和本文算法的分类准确率

Table 3 Classification accuracy of the baseline algorithm and the algorithm in this paper

算法	类别	<i>P</i>	<i>R</i>	<i>S</i>	<i>Acc</i>
ResNet	不导电	0.875	1.000	0.997	-
	凸粉	0.875	1.000	0.997	-
	擦花	0.576	0.760	0.962	-
	无缺陷	0.985	0.941	0.984	-
	桔皮	1.000	0.889	1.000	-
	横条压凹	0.900	1.000	0.997	0.916
	涂层开裂	1.000	1.000	1.000	-
	漏底	0.923	0.980	0.988	-
	碰伤	0.846	0.733	0.995	-
	脏点	0.846	0.805	0.983	-
	起坑	0.909	1.000	0.997	-
	本文算法	不导电	1.000	1.000	1.000
凸粉		0.875	1.000	0.997	-
擦花		0.815	0.880	0.986	-
无缺陷		0.990	0.980	0.989	-
桔皮		1.000	0.944	1.000	-
横条压凹		1.000	1.000	1.000	0.964
涂层开裂		1.000	1.000	1.000	-
漏底		0.961	1.000	0.994	-
碰伤		0.929	0.867	0.997	-
脏点		0.925	0.902	0.991	-
起坑		1.000	1.000	1.000	-

分析表 3 中分类算法对各类缺陷的分类精度可知，本文算法在铝材不导电、横条压凹、涂层开裂以及起坑的分类精确率、召回率和特异性达到了 100%，远超基准算法的分类精度。本文算法与基准算法相比，对铝材无缺陷样本的分类精确率、召回率和特异性分别由 98.5%、94.1%和 98.4%提升到 99.00%、98.00%和 98.90%，对无缺陷样本分类准确率具有较大提升，很大程度上能够避免工业在进行缺陷分类时将缺陷样本分类成正常样本，提升工业产品质量。本文算法相较于基准算法对铝材缺陷

的整体分类准确率提升了 4.8 个百分点。此外,对铝材擦花、桔皮、漏底、碰伤和脏点的分类精确率、召回率和特异性相对于基准算法也有着较大提升。综合来说,本文算法性能对多个类型的缺陷分类相较于基准算法具有一定优势,更适合多类别的工业缺陷分类任务中。

为直观对比本文算法和基准算法在训练过程中

的效果,实验测试了本文算法和基准算法的训练精度和训练损失,测试结果如图 3 所示。对比分析本文算法和基准算法的训练损失可知,本文算法的训练损失收敛速度更快。对比分析本文算法和基准算法的训练精度可知,本文的训练精度明显高于基准算法,且更为稳定。

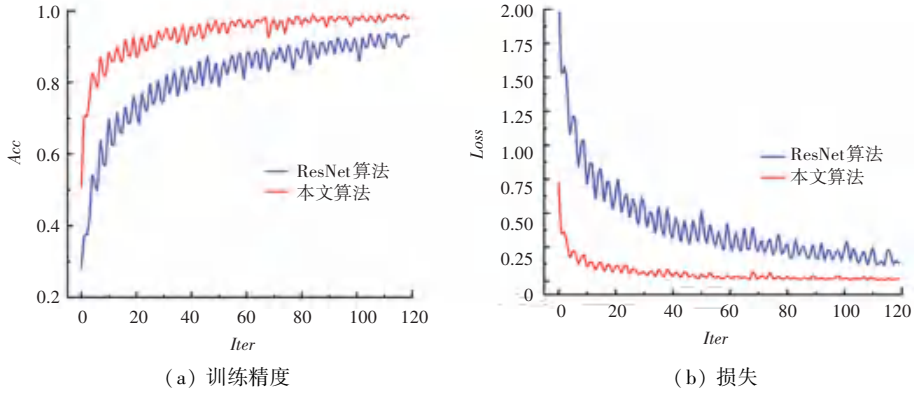


图 3 本文算法与基准算法的训练精度与损失

Fig. 3 The training accuracy and loss of the proposed algorithm compared to the baseline algorithm

2.5 可视化分析

为对比本文算法和基准算法的直观效果,对部分铝材缺陷样本的热力图进行了分析,如图 4 所示。图 4(a)~(c)中,从左至右依次为:不导电、擦花、漏底、碰伤、脏点。分析铝材不导电的热力图可以发现,本文算法对铝材缺陷区域的关注度更高;分析基准算法对铝材擦花和漏底的热力图可知,基准算法

存在无法将关注度集中在缺陷区域的问题,在对基准网络进行改进后,对铝材的缺陷区域的关注度大幅提升;分析铝材碰伤的热力图可知,本文算法对铝材的关注位置更接近缺陷区域,关注度更高;分析铝材脏点的热力图可知,本文算法更能准确找到需要关注的区域。综合来说,本文所提的算法在一定程度上能够缓解基准算法对铝材缺陷区域的关注度不足。

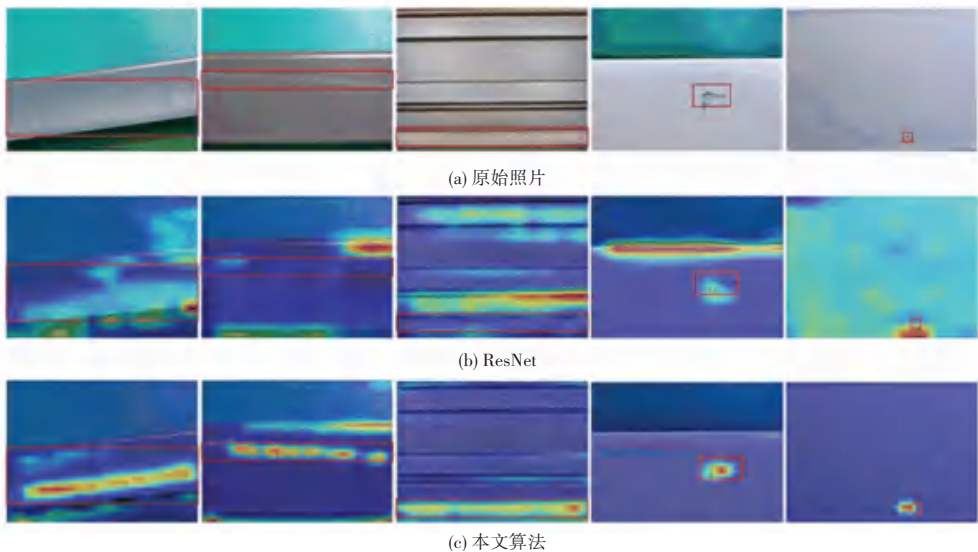


图 4 热力图效果对比图

Fig. 4 Comparison of heat map effect

3 结束语

本文为解决铝材表面缺陷不明显和缺陷尺度差异大导致缺陷类别难以识别的问题,提出了多尺度特征聚合的分类方法。将 ResNet 网络提取不同层的特征信息进行高效融合,并使用 GAM 注意力机制增强模型对各类别缺陷区域的关注度,进而增强各类别缺陷特征的差异性。此外,使用了改进的 CutMix 数据增强方法和多类别 FocalLoss 损失函数解决缺陷样本不足和类别不平衡的问题。本文在铝材缺陷样本数据集中进行了实验,实验结果表明,本文算法优于目前主流的分类算法,有效提升了铝材缺陷样本的分类准确率。但多尺度特征聚集融合方法在一定程度上增加了模型参数量,在未来工作中将研究该方法的轻量化,使用该方法解决缺陷分类落地困难的问题。

参考文献

- [1] CHEN Yajun, DING Yuanyuan, ZHAO Fan, et al. Surface defect detection methods for industrial products: A review[J]. Applied Sciences, 2021, 11(16): 7657.
- [2] CHEN K, ZENG Z, YANG J. A deep region-based pyramid neural network for automatic detection and multi-classification of various surface defects of aluminum alloys[J]. Journal of Building Engineering, 2021, 43: 102523.
- [3] REN Z, FANG F, YAN N, et al. State of the art in defect detection based on machine vision[J]. International Journal of Precision Engineering and Manufacturing - Green Technology, 2022, 9(2): 661-691.
- [4] JIA Hongbin, MURPHEY Y L, SHI Jianjun, et al. An intelligent real-time vision system for surface defect detection [C]// Proceedings of the 17th International Conference on Pattern Recognition (ICPR 2004). Piscataway, NJ: IEEE, 2004, 3: 239-242.
- [5] ZHANG Xuewu, DING Yanqiong, LV Yanyun, et al. A vision inspection system for the surface defects of strongly reflected metal based on multi-class SVM[J]. Expert Systems with Applications, 2011, 38(5): 5930-5939.
- [6] 梁丽媛,陈永当,胡梦麒,等. 基于支持向量机的纹理特征识别方法研究[J]. 智能计算机与应用, 2024, 14(4): 168-172.
- [7] HU Huijun, LIU Ya, LIU Maofu, et al. Surface defect classification in large-scale strip steel image collection via hybrid chromosome genetic algorithm[J]. Neurocomputing, 2016, 181: 86-95.
- [8] ZHAO Weidong, CHEN F, HUANG Haicheng, et al. A new steel defect detection algorithm based on deep learning[J]. Computational Intelligence and Neuroscience, 2021, 2021(1): 5592878.
- [9] 熊政,车文刚,保永莉,等. 基于改进的 MobilenetV3 热轧钢带表面缺陷分类 [J]. 兰州大学学报(自然科学版), 2024, 60(2): 182-186.
- [10] HOWARD A, SANDLER M, CHU G, et al. Searching for MobileNetV3 [C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway, NJ: IEEE, 2019: 1314-1324.
- [11] 翁佩纯,李蓉,张远海. 基于 ResNet 的焊接缺陷分类识别 [J]. 智能计算机与应用, 2023, 13(5): 103-106.
- [12] HE Di, XU Ke, ZHOU Peng, et al. Surface defect classification of steels with a new semi-supervised learning method[J]. Optics and Lasers in Engineering, 2019, 117(6): 40-48.
- [13] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2016: 770-778.
- [14] LIU Yichao, SHAO Zongru, NICO H. Global attention mechanism: Retain information to enhance channel - spatial interactions [J]. arXiv preprint arXiv, 2112.05561, 2021.
- [15] SANGDOO Y, DONGYOON H, SEONG J O, et al. CutMix: Regularization strategy to train strong classifiers with localizable features [C]// 2019 IEEE/CVF International Conference on Computer Vision (ICCV 2019). Piscataway, NJ: IEEE, 2019: 6022-6031.
- [16] TSUNG Y L, PRIYA G, ROSS G, et al. Focal loss for dense object detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 42(2): 318-327.
- [17] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2017: 2117-2125.
- [18] CHRISTIAN S, VINCENT V, SERGEY I, et al. Rethinking the inception architecture for computer vision [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2016: 2818-2826.
- [19] SAINING X, ROSS G, PIOTR D, et al. Aggregated residual transformations for deep Neural Networks [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ: IEEE, 2017: 5987-5995.
- [20] DING Xiaohan, ZHANG Xiangyu, MA Ningning, et al. RepVGG: Making VGG - style ConvNets great again [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ: IEEE, 2021: 13733-13742.
- [21] LIU Zhuang, MAO Hanzi, WU Chaoyuan, et al. A ConvNet for the 2020s [J]. arXiv preprint arXiv, 2201.03545, 2024.