文章编号:1674-2974(2024)04-0099-06 DOI:10.16339/j.cnki.hdxbzkb.2024175

基于深度学习的镍基高温合金叶片磨削烧伤识别研究

刘超[1],刘成[2],王虎[3†],陈亮[2],梁晓艳[2],金滩[3]
(1. 中国航发南方工业有限公司,湖南 株洲 412001;
2. 湖南南方通用航空发动机有限公司,湖南 株洲 412001;
3. 湖南大学 机械与运载工程学院,湖南 长沙 410082)

摘 要:针对目视检查镍基高温合金叶片磨削烧伤时易出现误检、漏检等问题,提出一种基于深度学习的镍基高温合金叶片磨削烧伤识别分类模型(Tenon Grinding Burn Net,TenonGBNet).以K4125镍基高温合金叶片为研究对象,通过磨削烧伤试验和试件组织检测获得不同烧伤程度的叶片榫齿磨削烧伤分级标准和对应的图片集;将ODConv动态卷积融合Inception V2模块和Coordinate Attention注意力机制,保证模型轻量化的同时提高模型的特征提取能力;使用全连接层进行识别分类.结果表明,与其他4个经典分类模型相比,TenonGBNet在具有较小的模型复杂度和参数量的同时保持了96.50%的平均分类准确率,且各烧伤等级的分类准确率均超过95%.

关键词:深度学习;镍基合金;磨削;烧伤;图像识别
中图分类号:TP391.4 **文献标志码**:A

Research on Grinding Burn Identification of Nickel-based Superalloy Blades Based on Deep Learning

LIU Chao[1], LIU Cheng[2], WANG Hu[3†], CHEN Liang[2], LIANG Xiaoyan[2], JIN Tan[3]
(1. AECC South Industry Co., Ltd, Zhuzhou 412001, China;
2. Hunan South General Aviation Engine Co, Ltd, Zhuzhou 412001, China;
3. College of Mechanical and Vehicle Engineering, Hunan University, Changsha 410082, China)

Abstract: A deep learning-based recognition and classification model named Tenon Grinding Burn Net (TenonGBNet) is proposed to address the issues of misdiagnosis and missed detection in visual inspection of grinding burns on nickel-based Superalloy blades. The K4125 nickel-based superalloy blades are chosen as the target, and through grinding burn tests and specimen organization inspection, a set of classification standards and corresponding image collection for different degrees of blade tenon grinding burns are obtained. Then, ODConv dynamic convolution is employed to fuse Inception V2 modules and the Coordinate Attention mechanism to enhance the model's feature extraction capability while ensuring the model is lightweight. Finally, a fully connected layer is employed for identification and classification. Experimental results indicate that, compared with four other classical classification models, TenonGBNet achieves an average classification accuracy of 96.50% while maintaining a minor

* **收稿日期**:2023-10-21
基金项目:中国航发南方工业有限公司合作项目(N-22120201), AECC South Industry Company Limited Cooperation Project (N-22120201)
作者简介:刘超(1984—),男,湖南株洲人,中国航发南方工业有限公司高级工程师
† 通信联系人,E-mail: wanghu01@hnu.edu.cn

model complexity and parameter count. Additionally, the classification accuracy for each burn level exceeds 95%.

Key words: deep learning; nickel alloy; grinding; burn; image identification

镍基高温合金叶片作为航空发动机的关键零部件,其榫齿结构目前多采用缓进深切成形磨削进行加工.由于榫齿结构的特殊几何形状,磨削区的传热机制十分复杂,易产生不同程度的磨削烧伤现象[1],导致榫齿表面质量降低,显微组织变化等问题,从而使得零件的抗疲劳性能下降,甚至引起裂纹和断裂等严重缺陷.因此,对于叶片榫齿磨削加工,准确快速地识别叶片榫齿的磨削烧伤具有重要的工程意义.

传统烧伤检测有目视检查、荧光检测、酸洗、金相检测、残余应力检测和组织检测等[2],其中目视检查为一线工人常用检查方法,但由于镍基高温合金叶片榫齿具有凹凸波浪状的高反光金属表面特性,易造成误检、漏检等情况,其余检测方法普遍等待周期长且成本偏高.鉴于此,提出一种快速的无损检测方法显得尤为必要.

随着图像处理技术、传感器和工业相机等硬件的不断迭代更新,使用机器视觉技术对工件表面磨削烧伤的检测已有大量研究[2].陈荣媛等[3]提取了烧伤图像的颜色特征,将工件表面烧伤的程度作定量表征与分级.Wang 等[4]提取金属金相组织在磨削烧伤后的二值化图像,将角二阶矩和对比度等 5 种图像特征值分别输入概率神经网络,实现了自动分类.Hübner 等[5]将磨削 2711 模具钢中发生烧伤的声发射信号时频域分析图片作为卷积神经网络模型的训练数据,最终信号在采用 STFT 短时傅里叶变换方法下生成的图片使网络模型获得了 99.4% 的判别准确率.孙为钊等[6]阐述了支持向量机在烧伤判别中的应用,并指出数据量是影响支持向量机判别精度的主要影响因素.周光辉等[7]采用迁移学习方法,将试验采集的钛合金数据集输入已经训练好权重参数的 GoogLeNet 和 ResNet50 网络模型中,可以准确识别 4 类磨削烧伤程度.

基于上述国内外对金属材料磨削烧伤的检测研究现状,为解决叶片榫齿磨削烧伤目测法受限于环境灯光和主观判断导致的效率较低且置信度不高问题,基于深度学习图像分类技术,利用 ODConv 动态卷积,融合 Inception V2 模块和 Coordinate Attention 注意力机制,在面向 K4125 镍基高温合金叶片榫齿磨削烧伤等级分类问题上设计搭建了 TenonGBNet 模型网络.该网络可根据叶片榫齿磨削烧伤图像进行磨削烧伤识别,为镍基高温合金叶片榫齿的磨削烧伤快速检测提供参考.

1 数据集建立

目前针对镍基高温合金磨削烧伤还没有相应的开源数据集,且基于深度学习的方法需要大量烧伤图像,否则数据样本不足导致网络模型易出现过拟合现象,表现出较差的泛化能力,从而导致模型分类准确度较低.参考中国航发某公司现有工艺参数,通过调整试验条件制造不同程度的榫齿磨削烧伤,并使用工业相机进行原始图像采集,最终在图像预处理后完成对榫齿磨削烧伤数据集的制作.

1.1 磨削烧伤试验

以 K4125 等轴晶镍基高温合金叶片作为试验工件,榫齿结构采用刚玉砂轮成形磨削,在砂轮线速度为 30 m/s 和工件进给速度为 150 mm/min 的固定参数下,逐级改变磨削深度以获得不同程度的磨削烧伤试样.其中磨削深度分别选取 7 组参数:0.03 mm、0.05 mm、0.10 mm、0.20 mm、0.50 mm、0.85 mm、1.20 mm,每组工艺参数重复磨削 10 次.

为了更快产生磨削烧伤并使烧伤表面的形貌呈现多样化和随机性,调整机床磨削液冷却泵使磨削液喷嘴出口压力约为 0.1 MPa,流量约为 7 L/min,同时砂轮修整采取磨 5 修 1 方式.磨削烧伤试验条件如表 1 所示.

表 1 磨削烧伤试验条件

Tab.1 Grinding burn test conditions

项目	设备与参数
机床	MKL7132X8/17 超高速数控磨床
砂轮	诺顿 F13A80FF22V 刚玉砂轮
冷却方式	单边随动冷却
修整参数	单点金刚石笔往复修整 2 次, 修整进给量 f_d=30 μm/r,光修 2 次

基于上述工艺参数共进行70次磨削试验,并按照中国航发某公司现有工艺磨削10组无烧伤试样,共获得80个具有榫齿结构的磨削加工表面.

1.2　图像采集与烧伤分级

图像质量往往对网络模型的参数学习和识别准确率有间接影响,对于分类任务来说,图像包含的细节越多,网络模型能学习到的特征参数就越多,最终的分类效果也就越准确.为了获得高质量的榫齿烧伤表面图像,采用MV-CE050-30UC工业相机采集原始榫齿表面图像.

由于波浪形曲面的榫齿镍基合金具有金属反光的特征,故选择合适的照明光源尤为重要.本文采用球积分光源正面光照的搭建方法,便于区分不同程度的磨削烧伤榫齿面颜色,且相比于常用的同轴光和环形光源能克服大部分反光干扰,进一步凸显榫齿面的磨削表面特征.

为了清晰地划分数据集的分类等级,对磨削烧伤表面的微观组织进行定量分析,本文参考《齿轮磨削后表面回火的化学浸蚀检验》(GB/T 17879—2023)中通过回火颜色和回火面积的最大百分数对磨齿烧伤程度的判定方式,采用德国徕卡DMi8A金相显微镜和Apreo S Lovac扫描电镜进行显微组织观察,根据金相组织中的γ′相变化情况辅以榫齿表面颜色和形貌特征[8],将榫齿磨削烧伤划分为4个等级,分别为0级无烧伤、1级轻度烧伤、2级中度烧伤和3级重度烧伤.不同烧伤等级的榫齿表面图像及显微组织变化如图1所示,烧伤类型对应参数如表2所示.

1.3　图像预处理

为了使网络模型在训练中快速收敛,并防止过拟合产生,往往需要对工业相机采集的原始图片进行图像预处理,增加训练样本并提高样本的多样性,从而提升模型的泛化性能[9].将原始图片由位图(.bmp)转换为RGB(.png)格式后,如图2所示,采用平移、旋转、随机裁剪、水平翻转等几何变换进行图像增广,

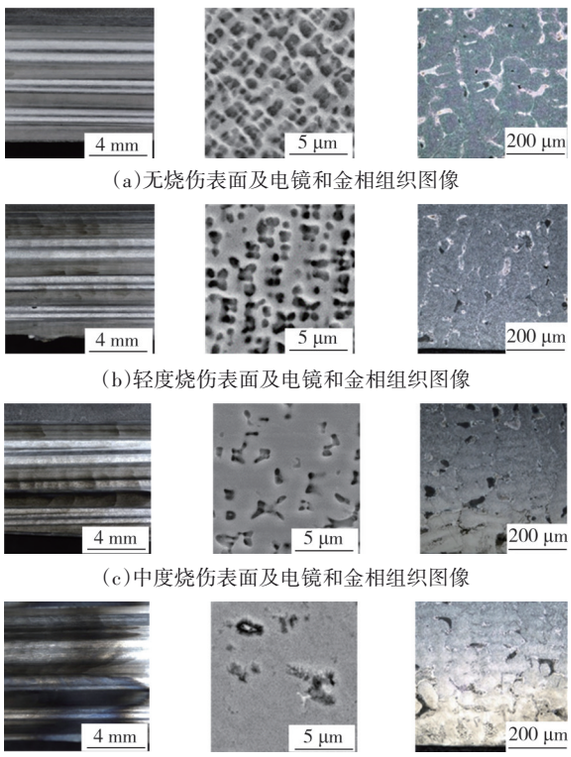

(a)无烧伤表面及电镜和金相组织图像

(b)轻度烧伤表面及电镜和金相组织图像

(c)中度烧伤表面及电镜和金相组织图像

(d)重度烧伤表面及电镜和金相组织图像

图1　不同烧伤等级的榫齿表面图像及显微组织变化

Fig.1　Surface images and microstructure changes of tenon teeth with different burn levels

最后将图片分辨率统一调整为224像素×224像素大小.扩充后的数据集共包含4 000张烧伤图片,每一烧伤等级按照8∶2的比例分为训练集和测试集.磨削烧伤图像数据集划分如表3所示.

2　基于深度学习的叶片磨削烧伤识别模型

根据图像分类领域的深度学习模型特点和叶片榫齿磨削烧伤图片的表面特征,使用ODConv动态卷积[10](以下简称OD动态卷积)融合Inception V2模块和Coordinate Attention注意力机制[11](以下简称CA模块),在面向K4125榫齿磨削烧伤等级分类问题上

表2　烧伤类型对应参数

Tab.2　Corresponding parameters of burn severity

项目	烧伤等级			
	无烧伤(0级)	轻度烧伤(1级)	中度烧伤(2级)	重度烧伤(3级)
显微组织分析	γ′相呈方块状,未见长大和回溶	距表面0.1 mm范围内γ′相轻微长大	距表面0.26 mm范围内γ′相存在长大回溶	距表面0.5 mm范围内γ′相存在长大回溶现象,局部出现初熔并伴有裂纹
表面形貌观察	表面光滑,呈金属反光	表面有絮状微黄色烧伤痕迹	呈褐色鳞状烧伤斑纹	明显的青黑色严重烧伤痕迹
采集图像	10张	23张	28张	19张

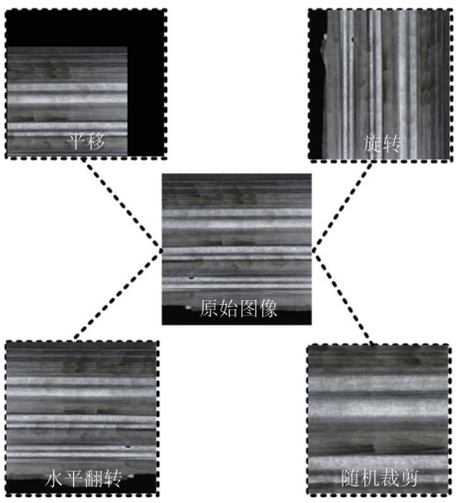

图 2 图像增广

Fig.2 Image augmentation

表 3 磨削烧伤图像数据集划分

Tab.3 Classification of grinding burn image dataset

项目	原始图片数	扩充后	训练集	测试集
无烧伤	10	1 000	800	200
轻度烧伤	23	1 000	800	200
中度烧伤	28	1 000	800	200
重度烧伤	19	1 000	800	200
总计	80	4 000	3 200	800

设计搭建了TenonGBNet模型网络. 通过优选的超参数设置,将TenonGBNet与几种典型的深度学习分类网络进行对比实验.

OD动态卷积是由Intel实验室提出的一种全维度动态卷积[10],利用多维度的注意力机制,沿着核空间的卷积核大小和个数、输入和输出通道数这4个维度更加灵活地并行学习卷积核的4种互补注意力类型. OD动态卷积操作在各维度的差异性使得其能够更好地获取丰富的输入图像信息,极大提升了卷积层的特征提取能力. 本文将模型的输入经过3次OD动态卷积操作,同时穿插加入2次最大池化操作来共同组成TenonGBNet模型的浅层部分.

榫齿磨削烧伤通常发生在齿顶部分,根据烧伤程度轻重表现出不同的烧伤颜色与纹理面积. 为了使TenonGBNet具有较高的分类准确率,并重点关注影响分类结果的局部区域,将OD动态卷积后的特征张量输入CA模块中. 即加入了坐标注意力机制的网络模型将输入的特征沿空间水平与垂直方向分别嵌入特定位置信息,使得模型能准确寻找并关注到含有烧伤信息的榫齿区域. 得益于CA模块的灵活轻量特点,TenonGBNet模型在提升性能的同时不会增加太多额外的计算开销.

为了进一步提升网络分类准确率且轻量化模型参数,考虑融合CA模块后使用两个Inception V2模块串联进一步提取深层特征信息,在减少计算复杂度的同时可以有效提升准确率. 在TenonGBNet模型的最后添加Dropout正则方法[12]以减少过拟合的发生,最终通过特征提取在全连接层实现分类. TenonGBNet模型组成结构如图3所示.

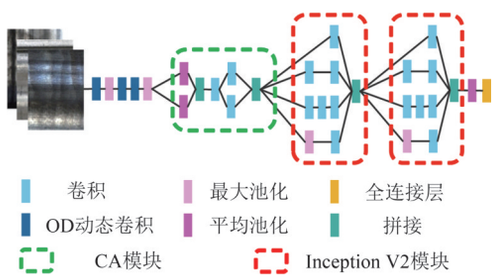

图 3 TenonGBNet模型组成结构

Fig.3 Composition structure of TenonGBNet model

基于开源的Pytorch框架搭建了TenonGBNet模型,模型中使用ReLU6激活函数[13],并规定图片的输入为224像素×224像素大小. 在训练网络模型阶段,设置训练回合数epoch为100,每回合训练样本数batch_size为64,学习率为0.001. 选择Adam优化器[14]并保持可调参数为默认值,损失函数采用交叉熵函数(Cross Entropy Loss).

为了说明TenonGBNet模型在叶片榫齿磨削烧伤等级分类识别中的良好表现,在上述超参数统一的情况下,分别选择4种经典的分类卷积神经网络模型AlexNet[15]、GoogLeNet[16]、DenseNet-121[17]、MobileNetV3-Small[18]共同进行对照实验,各模型迭代曲线如图4所示. 在模型训练中保留分类准确率最高的模型参数,并存储模型文件为.onnx格式.

从图4中可以看出,本文网络模型收敛快,40轮次左右达到最高验证集准确率,迭代过程平稳,且测试集识别准确率明显优于其他模型.

3 结果与分析

在多分类问题中通常采用准确率、精确率、召回率等指标评估模型分类泛化的性能. 为了综合度量模型在精确率和召回率的表现性能,采用F_1-score值作为TenonGBNet对比4种经典的分类卷积神经模型的评价指标,从图5中F_1-score数值对比可以明显发现,TenonGBNet在4种榫齿磨削烧伤等级的分类

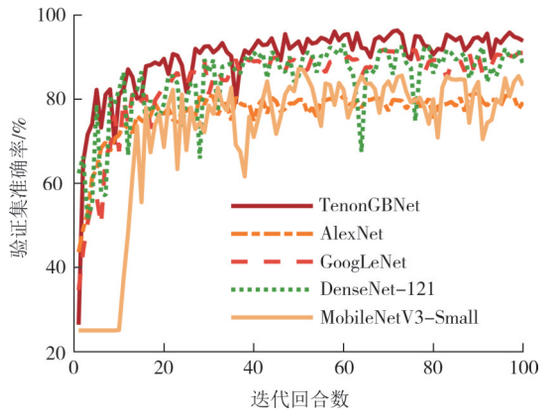

(a)验证集准确率

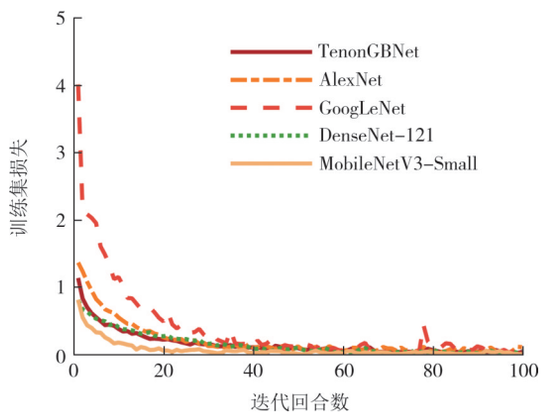

(b)训练集损失

图 4　各模型迭代曲线

Fig.4　Iteration curves of each model

中均具有最高的 F_1-score 值,其中无烧伤类别最高,达到0.98;而中度烧伤的 F_1-score 值为0.95,虽然在4类烧伤中数值最低,但远高于其他网络模型.

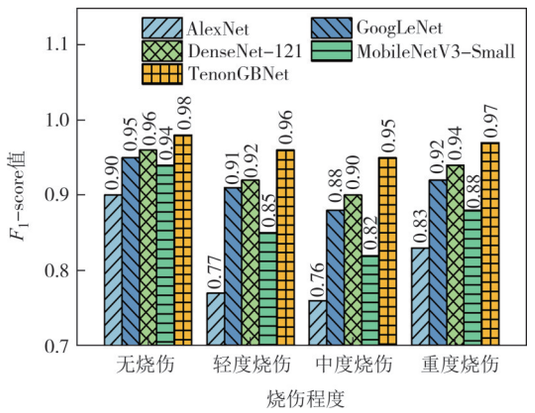

图 5　不同烧伤等级在网络模型上的 F_1-score 值

Fig.5　The F_1-score values of different burn grades on the network model

各模型对比实验结果表明,采用OD动态卷积和加入CA模块的TenonGBNet对不同等级的榫齿磨削烧伤都具备优良的特征提取能力.但部分中度烧伤既具有轻度烧伤表现出的灰褐色片状纹理,又具有与重度烧伤边缘相同的黑色,故对网络模型来说会造成分类准确率偏低的现象.

表4为不同模型相关参数对比,在分类准确率方面TenonGBNet模型达到96.50%,比准确率第二高的DenseNet-121网络高出约3%.另外,在不牺牲准确率的情况下,TenonGBNet模型中的参数量也仅为轻量级模型MobileNetV3-Small的1/3左右,这也使得其模型文件大小仅为2.4 MB,同时具有较低的浮点运算量,易于部署在移动端供设备使用.

表 4　不同模型相关参数对比

Tab.4　Comparison of different models related parameters

网络模型	图片像素	准确率/%	参数量/M	浮点运算量/G	模型文件大小/MB
AlexNet	224×224	81.50	14.59	0.31	55.6
GoogLeNet	224×224	91.75	5.98	1.58	22.8
DenseNet-121	224×224	93.13	6.96	2.89	26.8
MobileNetV3-Small	224×224	87.25	1.52	**0.06**	5.8
TenonGBNet	224×224	**96.50**	**0.49**	0.38	**2.4**

为了直观了解模型如何精确辨别烧伤等级,进一步验证模型的可靠性,采用类激活映射图(Class Activation Mapping,CAM)算法[19]展示TenonGBNet重点关注的特征区域.如图6所示,使用CAM技术生成不同烧伤程度图像的特征可视化热力图,颜色越深的区域对模型判定结果的影响程度越深.从图6中可以看出,针对无烧伤的图像样本,TenonGBNet模型关注了所有的榫齿顶部特征,这意味着模型对于无烧伤判断是基于整个榫齿磨削表面所作出的判断,十分符合人工观察关注的特征.同样地,针对存在烧伤的磨削表面图像,模型关注了出现烧伤痕迹的区域,且在同一磨削烧伤图像上着重关注了烧伤最严重的区域.因此,这充分表明TenonGBNet模型在判别榫齿磨削烧伤时与目测法观察到的判断信息基本一致,具有较高的可靠性.

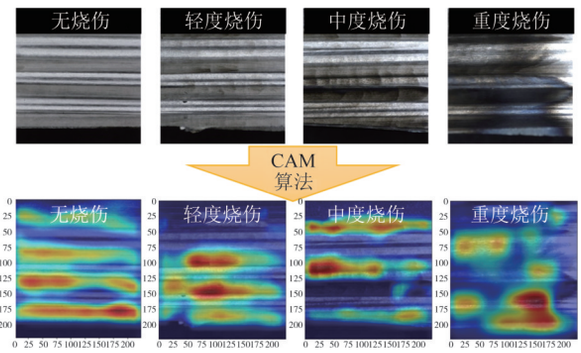

图6 TenonGBNet模型的不同烧伤程度类激活映射图

Fig.6 Class activation maps of different burn degrees of TenonGBNet model

4 结 论

1)基于Inception V2模块,结合OD动态卷积和CA模块搭建了TenonGBNet网络模型,能够准确识别航空发动机叶片榫齿在磨削中产生的烧伤等级.

2)基于磨削烧伤试验所采集的数据集在TenonGBNet和其他4个经典分类模型上进行深度学习训练实验,通过对比F_1-score值和分析模型参数,验证了TenonGBNet在拥有较少模型复杂度和参数量的同时保持了最高96.50%的准确率,最后通过类激活映射图形象直观地展示了模型在分类中的重点决策区域.

3)针对航空发动机叶片榫齿的磨削烧伤检测,基于深度学习的TenonGBNet模型可避免人为的误检、漏检等问题,是一种有效的检测手段,并可助力产线数字化和自动化转型升级.

参考文献

[1] 金滩, 何训, 王其荣, 等. 向极限挑战的高性能磨削技术发展及其在航空制造领域的应用前景[J]. 航空制造技术, 2022, 65(9): 20-33.
JIN T, HE X, WANG Q R, et al. Development of high performance grinding processes to challenge physical limitations: application prospects in aeronautical manufacture engineering[J]. Aeronautical Manufacturing Technology, 2022, 65(9): 20-33. (in Chinese)

[2] 何宝凤, 魏翠娥, 石照耀. 齿轮磨削烧伤检测方法研究现状及发展方向[J]. 仪器仪表学报, 2017, 38(8): 1889-1900.
HE B F, WEI C E, SHI Z Y. Researching status and developing direction of gear grinding burn detection methods[J]. Chinese Journal of Scientific Instrument, 2017, 38(8): 1889-1900. (in Chinese)

[3] 陈荣媛, 左敦稳. 采用CCD图像评价工件加工表面烧伤的可行性研究[J]. 苏州大学学报(工科版), 2005, 25(4): 48-52.
CHEN R Y, ZUO D W. Feasibility of evaluation for machining burn on work surface based on CCD image[J]. Journal of Soochow University(Engineering Science Edition), 2005, 25(4): 48-52. (in Chinese)

[4] WANG L, TIAN X L, LIU Q, et al. Grinding burn evaluation for 20CrMnTi steel based on binary images and neural network[J]. The International Journal of Advanced Manufacturing Technology, 2017, 93(9): 4033-4042.

[5] HÜBNER H B, DUARTE M A V, DA SILVA R B. Automatic grinding burn recognition based on time-frequency analysis and convolutional neural networks[J]. The International Journal of Advanced Manufacturing Technology, 2020, 110(7): 1833-1849.

[6] 孙为钊, 程庐山, 周俊. 基于支持向量机的磨削表面烧伤识别研究[J]. 计算机与数字工程, 2021, 49(8): 1682-1686.
SUN W Z, CHENG L S, ZHOU J. Research on grinding surface burn degree identification based on support vector machine[J]. Computer & Digital Engineering, 2021, 49(8): 1682-1686. (in Chinese)

[7] 周光辉, 卢文壮, 张其真, 等. 基于迁移学习的TC4钛合金磨削烧伤图像识别[J]. 机械制造与自动化, 2022, 51(2): 111-115.
ZHOU G H, LU W Z, ZHANG Q Z, et al. Image recongnition with respect to grinding burn of TC4 titanium alloy based on transfer learning[J]. Machine Building & Automation, 2022, 51(2): 111-115. (in Chinese)

[8] ZHANG Z H, LIU Y J, WANG Z D, et al. Influence behavior and mechanism of γ'-or γ''-precipitated phase types on damage resistance of heterogeneous interface in nickel-based superalloys[J]. Journal of Alloys and Compounds, 2022, 924: 166559.

[9] 陈禹乐, 李博, 梁红, 等. 小样本下基于深度学习的声呐图像分类研究[J]. 西北工业大学学报, 2022, 40(4): 739-745.
CHEN Y L, LI B, LIANG H, et al. Research on sonar image few-shot classification based on deep learning[J]. Journal of Northwestern Polytechnical University, 2022, 40(4): 739-745. (in Chinese)

[10] LI C, ZHOU A, YAO A. Omni-dimensional dynamic convolution [DB/OL]. (2022-09-16)[2023-10-21]. https://doiorg/10.48550/arXiv.2209.07947.

[11] HOU Q B, ZHOU D Q, FENG J S. Coordinate attention for efficient mobile network design[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, TN, USA: IEEE, 2021: 13708-13717.

[12] MENDENHALL J, MEILER J. Improving quantitative structure-activity relationship models using Artificial Neural Networks trained with dropout[J]. Journal of Computer-Aided Molecular Design, 2016, 30(2): 177-189.

[13] ZHANG Y D, MUHAMMAD K, TANG C S. Twelve-layer deep convolutional neural network with stochastic pooling for tea category classification on GPU platform[J]. Multimedia Tools and Applications, 2018, 77(17): 22821-22839.

[14] WANG Y J, ZHOU P Y, ZHONG W Y. An optimization strategy based on hybrid algorithm of Adam and SGD[J]. MATEC Web of Conferences, 2018, 232: 03007.

[15] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.

[16] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston, MA, USA: IEEE, 2015: 1-9.

[17] HUANG G, LIU Z, PLEISS G, et al. Convolutional networks with dense connectivity[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(12): 8704-8716.

[18] SANDLER M, HOWARD A, ZHU M L, et al. MobileNetV2: inverted residuals and linear bottlenecks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018: 4510-4520.

[19] ZHOU B L, KHOSLA A, LAPEDRIZA A, et al. Learning deep features for discriminative localization[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016: 2921-2929.