

DOI: 10.19650/j.cnki.cjsi.J2007072

焊接缺陷磁光成像卷积神经网络识别方法*

季玉坤¹, 高向东¹, 刘倩雯¹, 张艳喜¹, 张南峰²

(1. 广东工业大学广东省焊接工程技术研究中心 广州 510006; 2. 黄埔海关技术中心 广州 510730)

摘要:对焊件表面及亚表面微小焊接缺陷进行检测是保证焊接质量的关键,提出一种基于深层卷积神经网络的磁光成像焊接缺陷检测方法。以法拉第磁致旋光效应为基础,分析磁光成像原理,建立深层卷积神经网络预测模型,研究不同模型结构参数对训练结果的影响。通过对深度卷积神经网络中间机理分析,研究模型训练过程并自动寻找卷积核最优参数。试验结果表明,第一层卷积核尺寸选择 7×7 和采用Relu激活函数可以使预测模型达到最佳效果,焊接缺陷磁光成像平均训练准确率为98.61%,凹坑、裂纹、未焊透、未熔合、无缺陷5种焊接试样预测准确率分别为84.38%、98.05%、84.38%、100%、100%,平均预测准确率为93.36%。

关键词:焊接缺陷;磁光成像;卷积神经网络;无损检测

中图分类号: TH865 文献标识码: A 国家标准学科分类代码: 520.2060

Weld defect recognition method with magneto-optical imaging based on convolutional neural network

Ji Yukun¹, Gao Xiangdong¹, Liu Qianwen¹, Zhang Yanxi¹, Zhang Nanfeng²

(1. Guangdong Provincial Welding Engineering Technology Research Center, Guangdong University of Technology, Guangzhou 510006, China; 2. Huangpu Customs Technology Center, Guangzhou 510730, China)

Abstract: Detecting the surface and subsurface micro weld defects is the key to ensure welding quality. A weld defect detection method with magneto-optical imaging based on deep convolutional network is proposed. On the basis of Faraday magneto-optic rotation effect, the principle of magneto optical imaging is analyzed. A deep convolutional network prediction model is established to study the influence of different model structure parameters on the training results. Through analyzing the intermediate mechanism of deep convolutional neural network, the model training process is studied and the optimal parameters of convolution kernel are found automatically. Experiment results show that the optimal prediction model can be achieved by selecting the size of the first layer convolution kernel as (7×7) and using the Relu activation function. The average training accuracy of magneto-optical imaging of weld defects is 98.61%, and the prediction accuracies of 5 weld samples with pit, crack, incomplete penetration, incomplete fusion and non-defect are 84.38%, 98.05%, 84.38%, 100% and 100%, respectively, and the average prediction accuracy is 93.36%.

Keywords: weld defect; magneto-optical imaging; convolutional neural network; nondestructive testing

0 引言

焊接是一种高效、稳定、低成本加工工艺方法,对于汽车制造、石油化工、冶金机械和航空航天等领域十分重要^[1-3]。由于焊接功率、保护气体流量、焊接熔池状态及焊接材料状况等不可控因素,焊接过程中会产生裂纹、未

熔合、凹坑等缺陷,直接威胁焊接产品安全,甚至会造成重大事故^[4-5],因此必须对焊接产品进行质量检测。常用的焊接缺陷无损检测方法有射线检测、超声检测、磁粉检测、涡流检测、渗透检测等^[6-10]。以上方法均有其优势与不足,如射线法对人体及环境均有辐射伤害;超声检测不易检测形状复杂或表面不光滑的试件,且人为影响因素较大;磁粉检测工序复杂,只适用于检测试件表面或亚表

收稿日期:2020-11-03 Received Date: 2020-11-03

* 基金项目:国家自然科学基金(51675104)、广州市科技计划项目(202002020068,202002030147)资助

面缺陷;涡流检测需要复杂的信号处理技术;渗透法不易对表面粗糙试件检测。

基于实际焊接检测需求,提出一种基于深层卷积神经网络的磁光成像新型检测技术,与传统检测技术相比,磁光成像传感无损检测是一种结合磁、光和电等物理学科的技术,具有易操作、灵敏度高、携带方便等优点,可将焊接缺陷的磁场信息转化为二维磁光图,从而更有利于焊接缺陷识别^[11]。文献[12]研究交变磁场下焊接缺陷的趋肤效应机理和磁光成像规律,分析得出了不同频率下漏磁检测的实际探测深度。文献[13]针对交变磁场励磁磁光成像定向检测的局限性,提出一种由正交电感形成的旋转磁场对试件进行励磁方法,实现检测不同方向缺陷的功能。文献[14]对电弧增材制造试样中的缺陷进行磁光成像,利用灰度共生矩阵提取试件表面纹理特征,建立经 LM (Levenberg-Marquardt) 算法改进的 BP (back propagation) 神经网络模型对成形件表面质量进行分类预测,为电弧增材制造中试样缺陷检测提供新的研究思路。文献[15]利用动态磁光成像系统检测焊接缺陷,通过磁光图像周期性融合、主成分分析以及 BP 神经网络建立磁光图像焊缝缺陷检测模型,对未焊透、凹坑和裂纹等典型缺陷具有较高的检测精度。本文研究焊接缺陷磁光成像深层卷积神经网络识别检测方法,卷积神经网络是一种端到端检测模型,具有移植性好和精度高等特点^[16-17],可有效提高焊接缺陷磁光成像自动检测功能。

对焊接缺陷磁光图像进行数字化处理,并采用自助法进行采样,通过深层卷积神经网络研究不同卷积核尺寸、不同激活函数对检测效果的影响,寻找最佳的检测模型参数。研究每层网络输出特征图的特点,分析深层卷积网络模型的检测机理,从数学理论角度解释其原理,为自动化、智能化焊接缺陷检测提供理论与试验依据。

1 焊接缺陷磁光成像

1.1 焊接缺陷磁光成像检测原理

基于法拉第磁致旋光效应^[18-19],如图1所示,LED光源经过起偏器形成线偏振光,再经过反射镜和凸透镜后到达磁光介质内,并发生一定角度 θ 的旋转。设通过磁光介质的有效长度为 L ,磁感应强度为 B ,旋转 θ 可由公式表示为:

$$\theta = VBL \quad (1)$$

式中: V 为菲德耳常数。

旋转后的线偏振光再次通过凸透镜、反射镜及偏振器后,被COMS相机接收并转化为磁光图像。对焊接缺陷试件励磁,通过磁光成像装置将磁场转化为可视化磁光图像。




图1 磁光成像检测原理

Fig. 1 Magneto-optical imaging principle

1.2 焊接缺陷磁光图像预处理

采集凹坑、裂纹、未焊透、未熔合、无缺陷5种焊接试样,通过对原始图像旋转、对称等操作来增加样本集。如图2所示,图2(a)是用高倍显微镜获得的焊接裂纹缺陷试样,图2(b)是通过磁光传感器得到的焊接裂纹缺陷试样的磁光原始图像,图2(c)、图2(d)、图2(e)、图2(f)

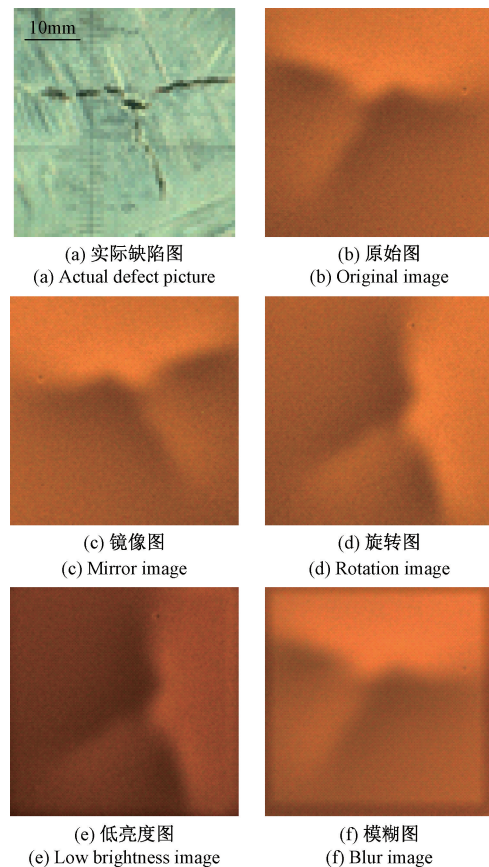


图2 焊接缺陷及其磁光图像

Fig. 2 Weld defect and its magneto-optical images

分别是在磁光原始图像基础上经过镜像、旋转、降低亮度、增加模糊度后得到的图像,最后将样本集统一成 400×400 pixel 大小图像。经过图像预处理后的图像样本集数量扩大,有助于加强深度卷积模型的鲁棒性,并防止过拟合现象。

将获得的样本集分成训练集与测试集的方法有留出法、交叉验证法、自助法。留出法直接将数据集划分为两个互斥的集合;交叉验证法先将数据集分成 k 个大小相似的互斥子集,每次用 $k - 1$ 个子集训练,其余子集用于测试。自助法直接以自主采样法为基础,每次从数据集中有放回地抽取一个样本,重复 m 次,就会得到一个包含 m 个样本的数据集,样本在 m 次采样中始终不被采到的概率是: $\left(1 - \frac{1}{m}\right)^m$, 对其取极限可以得到:

$$\lim_{m \rightarrow \infty} \left(1 - \frac{1}{m}\right)^m = \frac{1}{e} \approx 0.386 \quad (2)$$

通过自助采样并保证足够多的采样次数,理论上仍有 38.6% 的数据没有被选中,可选取采集到的数据作为模型训练数据集,而未被采集到的数据作为模型测试数据集。与前两种采样法相比,自助法在数据集较小、难以有效划分训练集/测试集时很有用。因此,采取自助采样法获得训练集与测试集,焊接缺陷数据集如表 1 所示。

表 1 焊接缺陷磁光图像数据集

Table 1 Magneto-optical image data set of weld defects

数据集	凹坑	裂纹	未焊透	未熔合	无缺陷
训练集	382	400	350	488	350
测试集	50	50	50	50	50

当采样次数 m 很大时,训练集中存在过多的重复训练样本,极易导致训练模型产生过拟合现象,不利于提高测试集检测精度。每种试样原始样本集数量为 135,分别进行自助采样,当剩余 50 个样本没被采样到时停止采样,此时采样次数 m 即为训练集样本数,而剩余 50 个没被采样到的样本即为测试集。

2 磁光成像卷积预测模型

2.1 前向传播

卷积神经网络主要由卷积层和池化层构成,分类任务中最后也会连接全连接层。卷积层是根据卷积核在输入的多通道磁光图像特征图上进行扫描与计算,得到多个具有较高层语义信息的焊接缺陷特征图。卷积核计算一个输出点的公式为:

$$C(m, n) = \sum_{i=1}^a \sum_{j=1}^b k(i, j) \times f(m + i - 1, n + j - 1) \quad (3)$$

式中: $k(i, j)$ 表示卷积核,大小为 $a \times b$; $f(m + i - 1, n + j - 1)$ 表示磁光图像特征图上的特征点。

输出特征图尺寸可用 $r_w \times r_h$ 表示,具体为:

$$r_w = \frac{l_w - w + 2p_w}{s_w} + 1 \quad (4)$$

$$r_h = \frac{l_h - w + 2p_h}{s_h} + 1 \quad (5)$$

式中: w 表示卷积核边长; l_h, l_w 分别表示输入特征图的长和宽; s_w, s_h 分别表示卷积核在特征图长和宽上的步长; p_w, p_h 分别表示卷积核在特征图长和宽上的填充长度。

由于卷积层具有局部连接和权值共享等特性,使得输入磁光图像与输出焊接缺陷信息在结构上可以保持对应关系,并使其具有远小于全连接层的参数与计算量。参数总量 C 与计算量 D 分别表示为:

$$C = c^i c^o k_w k_h \quad (6)$$

$$D = c^i c^o l_w^o l_h^o k_w k_h \quad (7)$$

式中: c^i 表示输入特征通道数; c^o 表示输出特征通道数; k_h, k_w 分别表示输入卷积核尺寸的长和宽; l_h^o, l_w^o 分别表示输出特征图尺寸的长和宽。

焊接缺陷磁光图像的卷积结构特点:随着层数的增加,输出特征图尺寸减少,特征图数量增加,减少计算量并提高训练速度。

池化层是在每层特征图上分开执行,且不需要参数控制,实现下采样功能并扩大磁光图像的感受野,简化网络复杂度,减少参数和计算量。磁光成像检测分类模型采用最大池化方式对特征图进行操作,可以减少卷积层参数误差造成的估计均值的偏移,以下是最大池化计算公式:

$$G(m, n) = \text{Max}(f(m + i - 1, n + i - 1)) \quad (8)$$

式中: i, j 的区间为池化核的长和宽; (m, n) 表示输出焊接缺陷特征图中的节点位置坐标。

在焊接缺陷磁光图像分类模型中,卷积层后会连接全连接层,并在最后加 Softmax 层作为输出层,可以将输出值控制在 0~1 之间,所有输出之和为 1,即输出值可以视为出现本类的概率值,如图 3 所示,全连接层输出 z_i 作为 Softmax 层输入,输出 y_i 可用公式表示为:

$$y_i = \frac{e^{z_i}}{\sum e^{z_i}} \quad (9)$$

式中: e^{z_i} 表示某一全连接层输出 z_i 的指数; $\sum e^{z_i}$ 表示全连接层输出 z_i 的指数加权和;输出 y_i 是焊接缺陷属于某一类别的预测概率,总和为 1。

2.2 迭代优化

迭代优化的首要步骤是计算损失,即前向传播预测焊接缺陷类别概率 y_i 与数据真实值 Y_i 的差异程度。交叉熵损失函数在图像分类中常用计算损失,表达式为:




图3 焊接缺陷磁光图像 Softmax 预测层

Fig. 3 Weld defect magneto-optical image Softmax prediction layer

$$S = \frac{1}{N} \sum_i - [Y_i \log(y_i) + (1 - Y_i) \log(1 - y_i)] \quad (10)$$

式中: N 表示所有焊接缺陷类型总数。

由式(10)可知: 当 $y_i = Y_i = 0$ 或 $y_i = Y_i = 1$ 时, $S = 0$; 当 $y_i = 1, Y_i = 0$ 或 $y_i = 0, Y_i = 1$ 时, $S = \infty$, 即 y_i 与 Y_i 相近时 S 变小, 反之变大。由于分类任务中用 Softmax 层, 则使用交叉熵函数作为损失函数可加快训练过程, 所以磁光成像检测分类模型采用交叉熵损失函数。迭代优化思想是根据损失值 S 对卷积核参数 W 求偏导, 由于式(8)、(9)均是关于参数 W 的函数, 根据梯度下降法可得反向参数更新公式为:

$$W = W_{pre} - A \times \frac{\partial S}{\partial W} \quad (11)$$

式中: A 为学习率, 表示参数更新步长。

当 A 设置较大时, 参数更新速度较快, 但最后会在最佳参数附近震荡; 当 A 设置较小时, 参数更新速度较慢, 且容易陷入局部最优点。针对以上问题, 焊接缺陷磁光图像分类模型设置学习率 A 随着训练次数 $epoch$ 适当改变, 以获得最佳参数, 优化后的 A 表达式为

$$A = \frac{1}{1 + decay_rate \times epoch} a_0 \quad (12)$$

式中: $decay_rate \times epoch$ 是超参数(可调); a_0 是学习率初始值。随着训练步数的增加, 学习率 A 会减少, 可以达到加快训练速度并能获得最优点的效果。

3 试验结果与分析

3.1 深度卷积模型参数评估

为了提高模型对焊接缺陷磁光图像分类的准确性和结构的适应性, 需要对模型不同的结构参数进行试验分析, 以获得最佳的模型。卷积核尺寸直接影响到感受野的大小, 卷积核越大, 感受野就越大, 输出的单一特征可以包含更多的信息。但当卷积核尺寸达到一定程度后, 会导致计算量暴增, 不利于模型深度增加, 因此计算性能也会下降。基于 5 个卷积层、5 个池化层、3 个全连接层的网络模型, 对比第一层卷积核尺寸 $w \times w$ 对分类结果的

影响, 由于奇数尺寸的卷积核对深度卷积神经网络模型具有更强的鲁棒性及应用扩展性, 因此设置试验卷积核尺寸 w 分别为 3, 5, 7, 9, 11。对应训练准确度及损失值如图 4、5 所示。




图4 不同卷积核尺寸训练准确率

Fig. 4 Training accuracies for different convolution kernel size




图5 不同卷积核尺寸损失值

Fig. 5 Loss values for different convolution kernel size

当迭代次数 S 达到 20 次时, 训练准确率已达到 75% 以上, 损失值下降到 4 以下, 截取训练步数 20~58 区间, 记录训练准确率 P_{tra} 及损失值标准差 $Loss_{tra}$, 综合预测准确率与单步训练时间, 如表 2 所示。当 w 由 3~7 过程中, 准确率标准差与损失标准差减小, 说明优化参数过程比较稳定, 容易达到最优值, 测试集准确率保持稳定; 当 w 由 7~11 过程中, 准确率标准差与损失标准差变化不明显, 而测试集准确率下降 0.39%。综上所述, 第一层卷积核最佳尺寸应为 7×7 。

神经网络中的激励层是对卷积层的输出结果做一次非线性映射。如果没有激励层, 则无论网络结构如何变化, 最终的输出仍是输入的线性组合, 无法拟合复杂数据集所含规律。激励层的核心是激活函数, 常用的激活函

表 2 不同卷积核尺寸训练结果

Table 2 Training results for different convolution kernel size

w×w	Acc_s	Loss_s	P_acc/%
3×3	0.067	0.127	93.36
5×5	0.052	0.159	93.35
7×7	0.028	0.079	93.36
9×9	0.059	0.162	92.19
11×11	0.026	0.066	92.97

数有 Sigmoid 函数、Tanh 函数、Relu 函数等,激活函数的斜率越大,则参数迭代更新的速度就越大,Sigmoid 函数与 Tanh 函数具有饱和区,可以防止训练过程中参数爆炸,斜率最大均在 $x=0$ 处。本试验模型在每一个 Pooling 层后均对数据进行归一化处理,可以保证卷积层输入均值在 $x=0$ 处。Relu 函数没有饱和区,优点是能够保证在正区间内更新迭代速度。不同激活函数在不同分类模型中的作用差别较大。因此,以上述 3 种激活函数为基础,分析其在焊接缺陷磁光图像分类模型中的性能优劣,对应训练准确度及损失值如图 6、7 所示。




图 6 3 种激活函数训练准确率

Fig. 6 Training accuracies for three activation functions

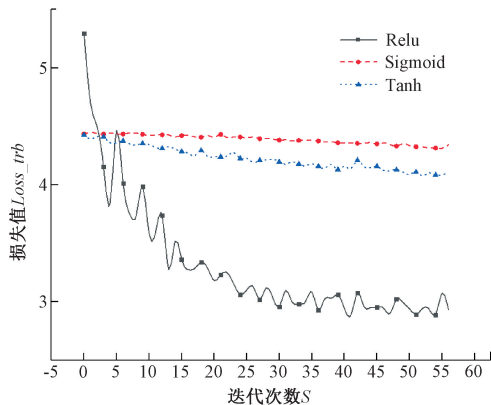


图 7 3 种激活函数损失值

Fig. 7 The loss values for the three activation functions

迭代步数 S 到达 58 次时,利用 Sigmoid 激活函数构成的预测模型训练准确度 P_{trb} 仍无法达到 80%;利用 Relu 激活函数构成的预测模型在保证较高及稳定的准确度之外,迭代步数到达 20 次后,其损失值均能保证在 3.5 以下,比另外两个激活函数的损失值下降较为明显。因此选择 Relu 函数作为激励层激活函数更适合焊接缺陷磁光成像分类模型。

3.2 焊接缺陷磁光图像分类模型

由 3.1 节分析,选择最佳深度卷积模型结构参数,对焊接缺陷磁光图像进行分类预测,如表 3 所示。其中初始学习率 $a_0=0.00005$;为防止过拟合现象采用 L1 正则化,正则化系数 $Regularizer=0.000001$;参数权重 Weight 均采用均值为 0,方差为 1 的正态函数初始化,参数偏置均设置 $z=0.1$ 常数初始化。随着深度卷积预测模型层数增加,每层输出尺寸的长和宽减小,而通道数在变大,参数量减少。

表 3 焊接缺陷磁光图像预测模型结构参数

Table 3 Structural parameters of the prediction model for weld defect magneto-optical image

Layer	Kernel Size	Output Size
Input		400×400
Convolution	64, 7×7	197×197
Max pooling	1, 2×2	98×98
Convolution	128, 3×3	98×98
Max pooling	1, 2×2	49×49
Convolution	256, 3×3	49×49
Max pooling	1, 2×2	24×24
Convolution	512, 3×3	24×24
Max pooling	1, 2×2	12×12
Convolution	512, 3×3	12×12
Max pooling	1, 2×2	6×6
Full connected	18432×128	128
Full connected	128×128	128
SoftMax	128×5	5

利用上述深度卷积预测模型对焊接缺陷磁光图像样本集进行训练及测试,由于训练过程是 5 种训练集混合一起参与训练卷积神经网络模型,最终训练集平均准确率为 98.61%。测试集预测结果如表 4 所示,裂纹、未熔合、无缺陷准确率较高,而凹坑、未焊透准确率较低,测试集平均准确率为 93.36%。分类类别对准确率有较大影响,导致这种现象有两种可能:1)磁光传感器没有完全采集到凹坑、未焊透焊接缺陷信息;2)模型的泛化能力不够,需要进一步调整预测模型机构。

表4 不同焊接缺陷预测结果

Table 4 Prediction results of different weld defects

测试集	准确率/%
凹坑	84.38
裂纹	98.05
未焊透	84.38
未熔合	100
无缺陷	100

3.3 深度卷积神经网络模型作用机制

深度卷积神经网络预测模型是一个端到端的“黑匣子”,即设置好模型结构和参数后,可将预处理后的图像直接进行输入,经过网络训练,就可以得到预测值。研究深度网络模型内部原理及每一层磁光图像输出特征图对焊接缺陷分类结果的作用,对深入优化更精确的预测模型具有指导性意义。以未熔合焊接缺陷磁光图像为例,分析图像经过每层卷积后,单通道输出特征图变化特点,如图8所示。

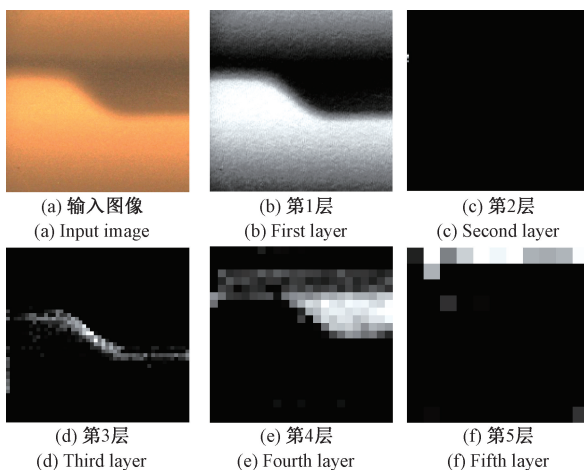


图8 未熔合试件卷积神经网络机理特征

Fig. 8 Feature of convolutional neural network mechanism of unfused specimens

由输入图像图8(a)到第1层卷积 Convolution 图8(b)输出,图像焊缝区域变得比较明显,类似于图像处理中阈值分割、滤波去噪等方法,分界线较为突出。图8(c)第2层输出特征图大部分区域像素值较小或为零,由于使用 Relu 激活函数,证明输入与参数卷积后大部分计算节点位于非正区间。图8(d)第3层卷积输出特征图理过程类似于进行了二值化处理或边缘化检测,焊缝特征更加明显。由表2可知,随着卷积层数的增加,通道数增多,输出特征图的长宽会较少,即像素点越少,所以图像会变模糊,每个单通道输出特征图只能包含输入图像的部分信息,如图8(e)、图8(f)所示。相比于传

统图像处理技术只能运用特定的卷积核进行图像处理,深度神经网络能够通过训练模型找到最优卷积核,并逐步提取磁光图像有效信息进行检测,具有更好的泛化性能。

4 结 论

基于法拉第磁致旋光效应,获取焊接缺陷磁光成像,利用自主采样法得到深度卷积神经网络模型的训练集和测试集,解决了数据集较小、难以有效划分训练集/测试集的问题。建立深度卷积焊接缺陷磁光成像训练模型,分析对比不同模型结构参数对预测结果的影响。实验结果表明:在其他模型结构参数不变的情况下,第一层卷积核尺寸为 7×7 ,激励层采用 Relu 激活函数,平均预测准确率可达到最大值 93.36%。研究深度神经网络中间机制,揭示了深层卷积神经网络对焊接试样的分类是逐步提取磁光图像有效信息并进行预测的过程。

参考文献

- [1] 高向东, 郑俏俏, 王春草. 旋转磁场下焊接缺陷磁光成像检测与强分类研究[J]. 机械工程学报, 2019, 55(17):61-67.
GAO X D, ZHENG Q Q, WANG CH C. Magneto-optical imaging detection and strong classification of weld defects in rotating magnetic field [J]. Journal of Mechanical Engineering, 2019, 55(17):61-67.
- [2] HUANG Y M, YUAN Y X, YANG L J, et al. Real-time monitoring and control of porosity defects during arc welding of aluminum alloys [J]. Journal of Materials Processing Technology, 2020, 286:116832.
- [3] XU X X, YOU G Q, DING Y H, et al. Microstructure and mechanical properties of inertia friction welded joints between high-strength low-alloy steel and medium carbon steel [J]. Journal of Materials Processing Technology, 2020, 286: 116811.
- [4] 焦敬品, 李思源, 常予, 等. 集箱管接头内焊缝表面缺陷识别方法研究[J]. 仪器仪表学报, 2017, 38(12): 3044-3052.
JIAO J P, LI S Y, CHANG Y, et al. Research on the surface defect identification method of internal welding seam in box pipe joint [J]. Chinese Journal of Scientific Instrument, 2017, 38(12):3044-3052.
- [5] ZERBST U, HENSEL J. Application of fracture mechanics to weld fatigue [J]. International Journal of Fatigue, 2020, 139:105801.
- [6] KIM K S, KANG S Y, KIM W S, et al. Improvement of radiographic visibility using an image restoration method based on a simple radiographic scattering model for X-ray nondestructive testing [J]. NDT & E International,

- 2018, 98: 117-122.
- [7] 尹昱, 陈振华, 肖峰, 等. 不锈钢疲劳微损伤的非线性超声检测方法[J]. 电子测量与仪器学报, 2020, 34(1): 68-73.
- YI Y, CHEN ZH H, XIAO F, et al. Nonlinear ultrasonic testing method for fatigue micro-damage of stainless steel [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(1): 68-73.
- [8] PAVEL S, ZBYNEK S. Automated magnetic field evaluation for magnetic particle inspection by impulse[J]. Journal of Nondestructive Evaluation, 2019, 38(3): 1-6.
- [9] ZHANG S, DUCHARNE B, UCHIMOTO T, et al. Simulation tool for the eddy current magnetic signature (EC-MS) non-destructive method [J]. Journal of Magnetism and Magnetic Materials, 2020, 513: 167221.
- [10] ARSLAN M, TOSUM L. Fracture load and microcrack comparison of crowns manufactured from tooth-shaped and traditional blocks [J]. Microscopy Research and Technique, 2020(5), DOI: 10.1002/jemt.23571.
- [11] GAO X D, MA N J, DU L L, et al. Magneto-optical imaging characteristics of weld defects under alternating magnetic field excitation [J]. Optics Express, 2018, 26(8): 9972-9983.
- [12] GAO X D, ZHOU X H, WANG CH C, et al. Skin depth and detection ability of magneto-optical imaging for weld defects in alternating magnetic field [J]. Journal of Manufacturing Systems, 2020, 55: 44-55.
- [13] GAO X D, LI Y F, ZHOU X H, et al. Multidirectional magneto-optical imaging system for weld defects inspection[J]. Optics and Lasers in Engineering, 2020, 124: 105812.
- [14] 何翔, 李亮玉, 王天琪, 等. 基于磁光成像的低碳钢 WAAM 成形件表面缺陷检测与分类[J]. 仪器仪表学报, 2020, 41(4): 255-262.
- HE X, LI L Y, WANG T Q, et al. Surface defects detection and classification of low carbon steel WAAM formed parts based on magneto-optical imaging [J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 255-262.
- [15] GAO X D, LAN C Z, YOU D Y, et al. Weldment nondestructive testing using magneto-optical imaging induced by alternating magnetic field [J]. Journal of Nondestructive Evaluation, 2017, 36(3): 55.
- [16] DU B L, HE Y G, HE Y Z, et al. Intelligent classification of silicon photovoltaic cell defects based on eddy current thermography and convolution neural network [J]. IEEE Transactions on Industrial Informatics, 2020, 16(10): 6242-6251.
- [17] 姜洪权, 贺帅, 高建民, 等. 一种改进卷积神经网络

模型的焊缝缺陷识别方法[J]. 机械工程学报, 2020, 56(8): 235-242.

JIANG H Q, HE SH, GAO J M, et al. An improved convolutional neural network model for weld defect identification is presented [J]. Journal of Mechanical Engineering, 2020, 56(8): 235-242.

- [18] MA N J, GAO X D, WANG CH C, et al. Influence of sampling frequency on magneto-optical imaging under alternating magnetic field excitation [J]. IEEE Sensors Journal, 2019, 19(23): 11591-11600.

- [19] KRUK A, MARIUSZ M. The measurement of faraday effect of translucent material in the entire visible spectrum [J]. Measurement, 2020: 107912.

作者简介



季玉坤, 2018年于河南科技大学获得学士学位, 现为广东工业大学硕士研究生, 主要研究方向为无损检测。

E-mail: 951612541@qq.com

Ji Yukun received his B. Sc. degree in 2018 from Henan University of Science and Technology. Now, he is a master student in Guangdong University of Technology. His main research interest is nondestructive testing.



高向东(通信作者), 1985年于郑州大学获得学士学位, 1988年于中南大学获得硕士学位, 1997年于华南理工大学获得博士学位, 现为广东工业大学机电工程学院教授、博士生导师, 主要研究方向为焊接自动化。

E-mail: gaoxid@gdut.edu.cn

Gao Xiangdong (Corresponding author) received his B. Sc. degree in 1985 from Zhengzhou University, M. Sc. degree in 1988 from Central South University and Ph. D. degree in 1997 from South China University of Technology. Now, he is a professor and Ph. D. supervisor in Guangdong University of Technology. His main research interest is welding automation.



张南峰, 2001年于广西大学获得学士学位, 2006年于华南农业大学获得硕士学位, 2014年于华南农业大学获得博士学位, 现为黄埔海关技术中心担任研究员, 主要研究方向为焊接自动化。

E-mail: 951612541@qq.com

Zhang Nanfeng received his B. Sc. degree in 2001 from Guangxi University, M. Sc. degree in 2006 and Ph. D. degree in 2014 both from South China Agricultural University. Now, he is a research fellow in Huangpu Customs Technology Center. His research interest is welding automation.