

DOI: 10.19650/j.cnki.cjsi.J2311266

# 基于深度学习主动视觉压力容器焊缝质量 参数检测方法<sup>\*</sup>

刘桂雄<sup>1</sup>, 廖 普<sup>1</sup>, 杨宁祥<sup>2</sup>

(1. 华南理工大学机械与汽车工程学院 广州 510640; 2. 广东省特种设备检测研究院珠海检测院 珠海 519001)

**摘 要:**压力容器 A、B 类对接焊缝是重要受力部位,其质量参数测量是焊接质量评估重要环节,本文研究基于深度学习主动视觉压力容器焊缝质量参数检测方法。提出多缺陷共存下焊缝参数计算方法,突破焊缝缺陷参数共存下存在焊缝质量参数难以计算或无法计算问题;开展编码-解码图像特征点提取网络(EDE-net)结构设计,较好实现焊缝表面参数特征点一次性准确提取;研究深度网络结构化通道剪枝方法,有效提高压力容器焊缝检测实时性能。以不同尺寸压力容器焊缝为实验对象,结果表明 Resnet50 骨干的 EDE-net 网络在模型整体压缩率  $CR=0.5$  下,单张图片提取时间由 0.31 s 降低到 0.19 s,减少 38.7%;第三方检测机构给出测试报告,装置同时测量对接焊缝(A、B 类)焊缝 5 个参数耗时 $<0.63$  s,测量误差允许误差 $\leq 0.08$  mm。

**关键词:**压力容器;焊缝表面参数;深度学习;模型剪枝。

中图分类号: 0439 TH74 文献标识码: A 国家标准学科分类代码: 460.40

## Active vision pressure vessel weld quality parameter detection method based on deep learning

Liu Guixiong<sup>1</sup>, Liao Pu<sup>1</sup>, Yang Ningxiang<sup>2</sup>

(1. School of Mechanical and Automotive Engineering, South China University of Technology, Guangzhou 510640, China;

2. Guangdong Province Special Equipment Testing and Research Institute Zhuhai Testing Institute, Zhuhai 519001, China)

**Abstract:** Class A and B butt welds of pressure vessels are important stress-bearing parts, and the measurement of their quality parameters is an important part of welding quality evaluation. This article studies the detection method of weld quality parameters of pressure vessels based on deep learning active vision. A calculation method for weld parameters is proposed under the coexistence of multiple defects, which breaks through the problem that the weld quality parameters are difficult or impossible to calculate under the coexistence of weld defect parameters. We carry out the structural design of the encoding-decoding image feature point extraction network (EDE-net), which can better realize the one-time and accurate extraction of weld surface parameter feature points. We study the deep network structured channel pruning method to effectively improve the real-time performance of pressure vessel weld detection. Taking the welds of pressure vessels of different sizes as the experimental objects, the results show that the EDE-net network with the backbone of Resnet50 has  $CR=0.5$  as the overall compression rate of the model, and the extraction time of a single image is reduced from the original 0.31 s to 0.19 s, a reduction of 38.7%. The test report is given by the third-party testing agency, and the device simultaneously measures 5 parameters of the butt weld (Class A, B) weld, which takes less than 0.63 s, and the allowable error of the measurement error is  $\leq 0.08$  mm.

**Keywords:** pressure vessel; weld surface parameters; deep learning; model pruning

## 0 引言

压力容器 A、B 类对接焊缝是重要受力部位,国家标准 GB 150—2011 规定的焊缝宽度、余高、咬边深度、错边量以及棱角度 5 个参数的焊缝三维形态参数直接反映焊接位置处应力集中程度,对其测量是焊接质量评估的重要环节<sup>[1-2]</sup>,目前比较成熟方法还是由人工使用放大镜、焊缝检验尺、棱角度尺等工具完成,存在精度低、效率低、工作量大、劳动强度大的问题。鉴于机器视觉检测方法具有非接触性、快速的特点,在焊接过程检测或焊缝三维形态参数部分参数已经有不同程度的研究与应用。主动视觉焊缝检测方法通常将结构激光打在焊缝表面,焊缝表面激光线呈现特定形状后成像,该曲线形状中焊缝表面参数信息的反映为曲线特征点<sup>[3-4]</sup>,从焊缝激光线中提取焊缝参数测量特征点是主动视觉焊缝测量重要内容<sup>[5]</sup>。

近年深度学习在机器视觉研究领域发展迅速,图像中提取指定特征点处理方法归类于姿态估计算法,将深度学习图像特征提取方法与主动视觉焊缝检测技术相结合,为焊缝检测领域提供一种新思路。文献[6]首次 DeepPose 网络用于图像特征估计,该网络前端采用深度卷积网络(convolutional neural networks, CNN)提取多尺度下图像特征信息,受限于当时 CNN 网络特征提取性能,DeepPose 准确度较低;文献[7]提出级联金字塔网络(cascaded pyramid network, CPN),网络分为 GlobalNet、RefineNet 两个部分,是目前特征点提取效果较佳网络。基于深度学习图像特征点提取算法网络结构加深,其提取准确性提高同时也会带来网络部署与正向传播慢问题<sup>[8]</sup>,深度学习加速方法是解决这个问题有效办法,它是利用深度网络结构、卷积层尺度与权重的冗余性精简模型,在达到相同输出精度下得到轻量化的卷积核与网络结构,减少过量网络参数导致计算时间长、模型过拟合、

泛化能力差等影响,其中结构化网络剪枝方法在层数较深 CNN 网络压缩效果明显,但需系统研究其剪枝优化函数设计、剪枝后精度恢复方法<sup>[9-12]</sup>。

本文在上述深度特征点提取网络与剪枝加速方法基础上,提出基于深度学习的主动视觉压力容器焊缝质量参数检测方法,包括压力容器焊缝表面多缺陷共存下参数计算方法、基于深度学习的压力容器焊缝参数特征点提取方法、深度特征点提取网络结构化通道剪枝方法等,有效提升压力容器 A、B 类焊缝质量参数检测性能。

## 1 基于深度学习的主动视觉压力容器焊缝质量参数检测框架

图 1 为本文提出的基于深度学习主动视觉压力容器焊缝质量参数检测框架图,包含焊缝表面轮廓成像、焊缝参数计算、特征点提取深度学习网络设计、深度学习网络训练等模块。其中,焊缝表面轮廓成像模块采用主动视觉成像装置,经系列图像处理后,得到焊缝轮廓点集  $S$ ,再由焊缝轮廓点集生成轮廓图像;焊缝参数计算模块突破焊缝质量参数特征点 ( $P_{re}$ 、 $P_{width}$ 、 $P_{un\_cut}$ 、 $P_{mis\_align}$ 、 $P_{peaking}$ ) 到余高  $h_{re}$ 、宽度  $l_{width}$ 、咬边  $h_{un\_cut}$ 、错边量  $h_{mis\_align}$ 、棱角度  $h_{peaking}$  数值计算,为多参数同时测量奠定理论基础;特征点提取深度学习网络设计模块采用“多层 CNN 降采样+反卷积上采样结构”主流架构设计深度学习特征点提取网络(encoding decoding characteristics extraction network, EDE-net)实现焊缝轮廓曲线图像,输出焊缝参数最佳估计特征点坐标,实现特征点准确提取;深度学习网络训练模块将实际采集焊缝轮廓图像与由图像增强的仿真焊缝图像一同训练初始化权重的 EDE-net,并将训练完成网络权重进行压缩,提高 EDE-net 正向传播实时性能,使得仪器在线测量成为可能。




图 1 基于深度学习的主动视觉压力容器焊缝质量参数检测框架图

Fig. 1 Framework for detecting quality parameters of pressure vessel weld seams based on deep learning

## 2 压力容器焊缝表面多缺陷共存下参数计算方法

根据 GB150—2011《压力容器》<sup>[13]</sup> 要求,压力容器焊缝以 A、B 类(纵、环焊缝)对接焊缝为主,其表面质量关键参数包括余高、宽度、咬边、错边量、棱角度等,图 2 为对接焊缝质量参数示意图(母材实线为纵焊缝、虚线为环




图 2 对接焊缝质量参数示意图

Fig. 2 Schematic diagram of butt weld quality parameters

受咬边缺陷  $h_{un\_cut}$  影响,严格定义下该咬边侧的  $P_{width}$ 、 $P_{mis\_align}$  特征点不存在,需估定  $\hat{P}_{width}$ 、 $\hat{P}_{mis\_align}$ ,图 3 为存在咬边缺陷  $h_{un\_cut}$  焊缝轮廓曲线局部放大图,图中咬边区域凹陷最低点为咬边特征点  $P_{un\_cut}$ ,母材曲线延长线与焊缝曲线延长线相交于宽度参数理想特征点  $P_{width}^{theor}$ ,但缺陷  $h_{un\_cut}$  存在,导致  $P_{width}^{theor}$  不在焊缝轮廓实体曲线上。令焊缝区域轮廓点集为  $P_{welded}$ ,若取  $P_{welded}$  中某点  $P_{width} \in P_{welded}$  作为宽度特征点,则该点在  $X, Y$  两个方向偏差  $\Delta_{width}(P_{width})$ 、 $\Delta_{height}(P_{width})$  分别为:

$$\begin{aligned} \Delta_{width}(P_{width}) &= |x_{width}^{theor} - x_{width}|; \\ \Delta_{height}(P_{width}) &= |y_{width}^{theor} - y_{width}| \end{aligned} \quad (1)$$




图 3 存在缺陷  $h_{un\_cut}$  焊缝轮廓曲线局部放大图

Fig. 3 Partial enlarged view of the weld profile curve with defect  $h_{un\_cut}$

可选取焊缝区域与咬边区域交点作为存在咬边缺陷  $h_{un\_cut}$  焊缝轮廓宽度参数  $l_{width}$  的  $\hat{P}_{width}$ ,  $\hat{P}_{width}$  为  $P_{welded}$  中最

焊缝)。主动视觉传感搭建焊缝表面质量参数检测模型,以上述标准定义测量示意作为参考,宽度  $l_{width}$ 、错边量  $h_{mis\_align}$  特征点为两侧焊趾点  $P_{width}^{left}(P_{mis\_align}^{left})$ 、 $P_{width}^{right}(P_{mis\_align}^{right})$ ;余高  $h_{re}$  特征点为曲线凸出部分顶点  $P_{re}$ ,若存在错变量,则这时焊缝两侧余高  $h_{re}^{left} \neq h_{re}^{right}$ ;咬边  $h_{un\_cut}$  特征点为曲线剧烈凹陷之谷  $P_{un\_cut}$ ,若焊缝两侧咬边存在,则分为  $h_{un\_cut}^{left}$ 、 $h_{un\_cut}^{right}$  <sup>[14]</sup>。

靠近  $P_{width}^{theor}$  点,这是由于:

$$\forall P_{width} \in P_{welded}, \Delta_{width}(P_{width}) + \Delta_{width}(P_{width}) \geq \Delta_{width}(\hat{P}_{width}) + \Delta_{width}(\hat{P}_{width}) \quad (2)$$

同时,考虑训练集标注方便性,可选择母材区与咬边凹陷区交界点为  $\hat{P}_{mis\_align}$ ,作为存在咬边缺陷  $h_{un\_cut}$  焊缝轮廓错边量  $h_{mis\_align}$  最佳估计特征点。

因此,找到最佳估计特征点  $\hat{P}_{width}$ 、 $\hat{P}_{mis\_align}$  后,再结合已有特征点  $P_{re}$ 、 $P_{un\_cut}^{left}$ 、 $P_{un\_cut}^{right}$ ,多缺陷共存下参数  $h_{re}^{left}$ 、 $h_{re}^{right}$ 、 $l_{width}$ 、 $h_{un\_cut}^{left}$ 、 $h_{un\_cut}^{right}$ 、 $h_{mis\_align}$  均可计算<sup>[14]</sup>,这样就可克服焊缝缺陷参数共存下存在焊缝质量参数难以计算或无法计算问题。

缺陷共存情况下,对于主动机器视觉采用文献<sup>[13]</sup>的标准推荐的预定直径样板法不便于在线测量,需重新研究新测量计算方法,得到  $\hat{h}_{peaking}$ 。由于 A、B 类焊缝棱角度特征差别较大,下面分别从 A、B 类焊缝棱角度定义出发,系统分析研究压力容器焊缝表面多缺陷共存下主动视觉棱角度  $h_{peaking}$  参数测量计算方法。

A 类纵焊缝棱角度  $h_{peaking}$  反映实际卷制钢板圆筒与设计压力容器理论圆弧偏离情况,由焊缝两侧母材轮廓曲线预测宽度特征点  $P_{width}^{left}$ 、 $P_{width}^{right}$  在  $X$  轴方向中点位置  $\hat{P}_{peaking}$ ,属于数据趋势预测问题。压力容器多缺陷共存 A 类焊缝母材曲线多为不规则曲线,对于不规则曲线趋势预测可用采用逻辑回归方法实现。为提高逻辑回归方法适用性,可采用增长型分段逻辑回归(piece-wise logistic regression, PLR)的 A 类纵焊缝虚拟特征点估计方法。对于增长率  $k_{PLR}$ 、总量  $T_{PLR}$ 、微调参数  $\beta_{PLR}$ ,由于母材点集不同位置增长率  $k_{PLR}$ 、总量  $T_{PLR}$  随位置变化,在点集长度为  $n$  的焊缝母材轮廓点集  $S = \{s_1, s_2, \dots, s_n\}$  中引入分界点

$CP = \{cp_1, cp_2, \dots, cp_m\} \subset S, n \geq m$ , 定义  $\lambda = \{\lambda_1, \lambda_2, \dots, \lambda_m\}, \lambda_i \sim \text{Laplace}(0, \tau)$  即服从拉普拉斯分布, 点集  $S$  任意分界点区域内增长率  $k_{\text{PLR}}(x)$ 、 $b_{\text{PLR}}(x)$  分别服从正态分布  $k_{\text{PLR}}(x) \sim N(0, \sigma_k^2)$ 、 $b_{\text{PLR}}(x) \sim N(0, \sigma_b^2)$ ,  $\beta_{\text{PLR}}(x)$  服从正态分布  $\beta_{\text{PLR}}(x) \sim N(1, \sigma_\beta^2)$ , 改进增长型 PLR 为<sup>[15]</sup>:

$$\begin{cases} f(x) = \frac{T_{\text{PLR}} + a_i(x)\lambda_i}{1 + (\beta_{\text{PLR}} + a_i(x)\lambda_i)e^{-[k_{\text{PLR}} + a_i(x)\lambda_i][x - b_{\text{PLR}} - \nu(x)]}} \\ \nu(x) = (cp_i - b_{\text{PLR}} - \sum_{j < i} \nu(x)) \left( 1 - \frac{k_{\text{PLR}} + \sum_{j < i} \lambda_j}{k_{\text{PLR}} + \sum_{j \leq i} \lambda_j} \right) \end{cases} \quad (3)$$

其中,  $i = 1, \dots, m; a_i(x) = \begin{cases} 1, & cp_i \leq x < cp_{i+1} \\ 0, & \text{其他} \end{cases}$

这就是用于 A 类纵焊缝两侧母材轮廓曲线预测宽度特征点  $P_{\text{width}}^{\text{left}}, P_{\text{width}}^{\text{right}}$  在  $X$  轴方向中点位置  $\hat{P}_{\text{peaking}}$  的数据趋势预测模型。

B 类环焊缝棱角角度  $h_{\text{peaking}}$  反映直板母材接头处突出情况, 由焊缝两侧母材轮廓直线预测宽度特征点  $P_{\text{width}}^{\text{left}}, P_{\text{width}}^{\text{right}}$  在  $X$  轴两侧的中间位置处  $\hat{P}_{\text{peaking}}^{\text{left}}, \hat{P}_{\text{peaking}}^{\text{right}}$ , 属于数据趋势预测问题, 压力容器多缺陷共存焊缝母材直线可采用贝叶斯线性回归方法实现。由于实际多缺陷共存 B 类环焊缝母材部分多为非规则直线, 噪声较大, 经典贝叶斯线性回归难以胜任其预测问题, 可采用分段贝叶斯线性回归模型 (piecewise Bayes liner regression, PBLR) 的 B 类环焊缝虚拟特征点估计方法。具体思路是在经典贝叶斯线性回归基础上, 引入噪声调整值  $m_{\text{PBLR}}$ , 且  $m_{\text{PBLR}}$  服从正态分布  $m_{\text{PBLR}} \sim N(0, \sigma_m^2)$ 。在点集长度为  $n$  的焊缝母材轮廓点集  $S = \{s_1, s_2, \dots, s_n\}$  中引入分界点  $CP = \{cp_1,$

$cp_2, \dots, cp_m\} \subset S, n \geq m$ , 定义  $\lambda = \{\lambda_1, \lambda_2, \dots, \lambda_m\}, \lambda_i \sim \text{Laplace}(0, \tau)$  即服从拉普拉斯分布, 点集  $S$  任意分界点区域内增长率  $k_{\text{PBLR}}(x)$  服从正态分布  $k_{\text{PBLR}}(x) \sim N(0, \sigma_k^2)$ , 令  $b_{\text{PBLR}}$  为偏置值, PBLR 模型为<sup>[15]</sup>:

$$g(x) = [k_{\text{PBLR}} + a_i(x)\lambda_i]x + b_{\text{PBLR}} + m_{\text{PBLR}}$$

其中,  $i = 1, \dots, m; a_i(x) = \begin{cases} 1, & cp_i \leq x < cp_{i+1} \\ 0, & \text{其他} \end{cases}$

(4)

这就是用于 B 类环焊缝两侧母材轮廓曲线预测宽度特征点  $P_{\text{width}}^{\text{left}}, P_{\text{width}}^{\text{right}}$  在  $X$  轴方向中点位置  $\hat{P}_{\text{peaking}}$  的数据趋势预测模型。

### 3 基于深度学习压力容器焊缝参数特征点提取方法

压力容器焊缝参数特征点提取网络采用图 4 所示 EDE-net 网络结构, 网络输入为焊缝轮廓曲线图像  $G_{\text{weld}}$ , 网络输出为参数特征点像素坐标信息, 其中编码器采用与 CNNs 骨干网络 (VGG<sup>[16]</sup>、Resnet<sup>[17]</sup> 等), 拓展能力强; 解码器采用二分支 3 层反卷积结构, 提高泛化能力质量及减少网络训练难度。此外, 考虑到 EDE-net 网络输出特征点应该是激光轮廓曲线上的点, 可采用如下校正方法提升特征点提取准确度。设网络输出焊缝特征点坐标为  $(x_{\text{out}}, y_{\text{out}})$ , 激光轮廓上任一点坐标为  $(x_R, y_R)$ , 校正后激光线上焊缝特征点坐标为  $(x_{\text{adj}}, y_{\text{adj}})$ , 那么校正提升公式如下:

$$(x_{\text{adj}}, y_{\text{adj}}) = \operatorname{argmin}[(x_{\text{out}} - x_R)^2 + (y_{\text{out}} - y_R)^2] \quad (5)$$




图4 压力容器焊缝参数特征点提取网络 EDE-net 网络

Fig. 4 EDE-net network for feature point extraction of welding seam parameters in pressure vessels

训练集制作方法可使用基于主动视觉成像装置采集焊缝表面轮廓图像, 在每幅图像中人工标注特征点位置坐标, 但存在工作量大、耗时, 甚至还存在样本数量有限

问题, 须采用压力容器焊缝表面多缺陷共存下质量参数图像增强方法<sup>[18]</sup>, 主动视觉成像焊缝表面轮廓曲线包含母材区、焊缝区两个部分, 其中母材区轮廓曲线即为压力

容器原有轮廓曲线,表现为椭圆弧线,焊缝参数焊缝曲线可采用3次非均匀有理B样条曲线(non-uniform rational B-splines, NURBS)仿真的图像增强方法。

#### 4 深度特征点提取网络结构化通道剪枝方法

EDE-net 的 CNNs 骨干网络结构越深,提取准确性越高,但也带来训练耗时长、正向传播慢等问题,结构化网络剪枝的深度加速方法在层数较深 CNN 网络压缩效果明显。令 Resnet 结构总层数为  $N$ ,第  $t$  层卷积计算权重矩阵为  $\mathbf{W}^t \in \mathbb{R}^{n^t \times c^t \times k^t \times k^t}$ ;输入特征图、经  $t$  层卷积计算输出特征图分别为  $\mathbf{F}_{in}^t \in \mathbb{R}^{c^t \times h_{in}^t \times w_{in}^t}$ 、 $\mathbf{F}_{out}^t \in \mathbb{R}^{n^t \times h_{out}^t \times w_{out}^t}$ ,则:

$$\mathbf{F}_{out}^t = \mathbf{W}^t \otimes \mathbf{F}_{in}^t \quad (6)$$

训练完成卷积权重矩阵  $\mathbf{W}^t$  多为满秩矩阵。CNNs 模型正向传播计算耗时长,结构化通道剪枝途径是寻找近似权重矩阵  $\mathbf{W}^t$  部分通道置0或低秩(部分权重特征值置0)剪枝权重矩阵  $\hat{\mathbf{W}}^t$ 。

方法1)通道置0处理:将  $\mathbf{W}^t$  中任意通道(第  $c_p$  通道)内全部元素置0系结构化通道剪枝通常办法<sup>[19]</sup>,即:

$$\hat{\mathbf{W}}^t = PR(\mathbf{W}^t, c_p), \hat{\mathbf{W}}^t_{:,i,:} = \begin{cases} 0, & i = c_p \\ \mathbf{W}^t_{:,i,:}, & i \neq c_p \end{cases} \quad (7)$$

方法2)低秩处理:卷积权重矩阵  $\mathbf{W}^t$  低秩处理,即对  $\mathbf{W}^t$  进行 SVD 分解<sup>[20]</sup>,将四维权重矩阵  $\mathbf{W}^t$  转换成二维  $\mathbf{M}^t \in \mathbb{R}^{n^t \times l^t}$ 。令  $l^t = c^t k^t k^t$ 、 $\mathbf{U}^t \in \mathbb{R}^{n^t \times n^t}$ 、 $\mathbf{\Sigma}^t \in \mathbb{R}^{n^t \times l^t}$ 、 $\mathbf{V}^t \in \mathbb{R}^{l^t \times l^t}$ ,则有:

$$\mathbf{M}^t = \mathbf{U}^t \mathbf{\Sigma}^t \mathbf{V}^{tT} \quad (8)$$

其中,  $\mathbf{\Sigma}^t$  为斜对角为  $\mathbf{M}^t$  特征值的主对角矩阵,特征值个数  $r^t = \min(n^t, l^t)$ 。将矩阵  $\mathbf{\Sigma}^t$  中第  $r_{id}$  个特征值进行剪枝操作  $TD(\mathbf{W}^t, r_{id})$ ,得矩阵  $\hat{\mathbf{\Sigma}}^t_{i,i}$ :

$$\hat{\mathbf{\Sigma}}^t_{i,i} = \begin{cases} 0, & i = r_{id} \\ \mathbf{\Sigma}^t_{i,i}, & i \neq r_{id} \end{cases} \quad (9)$$

令  $\sqrt{\hat{\mathbf{\Sigma}}^t} \mathbf{V}^{tT} = \hat{\mathbf{M}}_1^t$ 、 $\mathbf{U}^t \sqrt{\hat{\mathbf{\Sigma}}^t} = \hat{\mathbf{M}}_2^t$ ,  $\hat{\mathbf{M}}_1^t$ 、 $\hat{\mathbf{M}}_2^t$  为二维矩阵,其特征值个数  $\hat{r}^t < r^t$ ,即实现了  $\mathbf{W}^t$  低秩处理;最后,再将二维矩阵  $\hat{\mathbf{M}}_1^t$ 、 $\hat{\mathbf{M}}_2^t$  转换回四维矩阵  $\hat{\mathbf{W}}_1^t \in \mathbb{R}^{r^t \times c^t \times k^t \times k^t}$ 、 $\hat{\mathbf{W}}_2^t \in \mathbb{R}^{n^t \times r^t \times 1 \times 1}$ ,即可将单次卷积计算  $\mathbf{F}_{out}^t = \mathbf{W}^t \otimes \mathbf{F}_{in}^t$ ,转化为两次卷积计算式:

$$\mathbf{F}_{out}^t = \hat{\mathbf{W}}_1^t \otimes \hat{\mathbf{W}}_2^t \otimes \mathbf{F}_{in}^t \quad (10)$$

具体结构化通道剪枝方法可将  $\mathbf{W}^t$  部分通道置0、SVD 分解低秩处理方法相结合,形成综合单卷积权重通道剪枝方法。

设应用综合单卷积权重通道剪枝方法,第  $t$  层卷积权重矩阵  $\mathbf{W}^t$  可压缩单元为  $c^t + r^t$ ,剪枝  $d_c^t$  个通道、 $d_r^t$  个特

征值后剪枝卷积核分别为  $\tilde{\mathbf{W}}_1^t \in \mathbb{R}^{(r^t - d_r^t) \times (c^t - d_c^t) \times k^t \times k^t}$ 、 $\tilde{\mathbf{W}}_2^t \in \mathbb{R}^{n^t \times (r^t - d_r^t) \times 1 \times 1}$ ,依据剪枝后卷积计算所减少计算量,  $\mathbf{W}^t$  压缩率  $CR^t$  定义为<sup>[21-22]</sup>:

$$CR^t = 1 - \frac{k^t \times k^t (r^t - d_r^t) (c^t - d_c^t) + n^t (r^t - d_r^t)}{n^t \times c^t \times k^t \times k^t} \quad (11)$$

对于给定网络整体压缩率  $CR$ ,各层卷积权重矩阵最佳通道置0个数  $d_c^t$ 、特征值置0个数  $d_r^t$  不同,压缩率  $CR^t$  也不同,获取每层最佳压缩率  $CR^t$  是单卷积权重通道剪枝首要任务。因此,可遍历网络每层卷积,分别计算通道置0、特征值置0后剪枝权重  $\tilde{\mathbf{W}}^t$  与原始权重  $\mathbf{W}^t$  差异,通过最优化问题求解每层卷积权重最佳压缩率  $CR^t$ 。最后再经通道置0、SVD 分解权重特征值置0等处理压缩每层卷积权重至最佳压缩率。

#### 5 实验与结果分析

实验以图5所示的压力容器为对象,其中图5(a)~(f)分别为  $\Phi 550$  mm 压力管道 A 类纵焊缝、 $\Phi 250$  mm 压力管道 A 类纵焊缝、 $\Phi 600$  mm 压力管道 A 类纵焊缝、 $\Phi 120$  mm 压力管道 B 类环焊缝、 $\Phi 140$  mm 压力管道 B 类环焊缝、 $\Phi 180$  mm 压力管道 B 类环焊缝。




图5 压力容器焊缝轮廓图像特征点提取算例实验压力容器对象与主动视觉成像

Fig. 5 Feature point extraction of pressure vessel weld profile image experimental pressure vessel object and active vision

实验硬件包括主动视觉成像用 APTI NAMT 9P001CMOS 工业相机(焦距 8 mm、成像分辨率 800×600)、一字线激光器(波长 650 nm)、基恩士 LJV-7080 激

光轮廓传感器;边缘计算硬件 CPU 为 i7 8700k、内存 32 G、GPU 为 GeForce GTX 1080Ti。

图像数据集(测试集、训练集):压力容器 A 类纵向、B 类环向焊缝实体采集轮廓图像数据(人工标记)和仿真增强轮廓图像数据各 300 张,分别记:  $\mathbf{D}^{\text{real}}(300) = \{\mathbf{D}_3^{\text{real}}, \mathbf{D}_5^{\text{real}}, \mathbf{D}_7^{\text{real}}\}(300)$ 、 $\mathbf{D}^{\text{simu}}(300) = \{\mathbf{D}_3^{\text{simu}}, \mathbf{D}_5^{\text{simu}}, \mathbf{D}_7^{\text{simu}}\}(300)$ , 选取  $\mathbf{D}^{\text{real}}(300)$  中 60 张实体采集轮廓图像构成训练过程测试集,记为:  $\{\mathbf{D}_{\text{val}3}^{\text{real}}, \mathbf{D}_{\text{val}5}^{\text{real}}, \mathbf{D}_{\text{val}7}^{\text{real}}\}(60)$ ,其余 540 张轮廓图像数据集  $\mathbf{D}_{\text{train}3}, \mathbf{D}_{\text{train}5}, \mathbf{D}_{\text{train}7}$  供训练集选用,含  $\mathbf{D}_3^{\text{real}}, \mathbf{D}_5^{\text{real}}, \mathbf{D}_7^{\text{real}}$  中 240 张实体采集轮廓图像训练集  $\{\mathbf{D}_{\text{train}3}^{\text{real}}, \mathbf{D}_{\text{train}5}^{\text{real}}, \mathbf{D}_{\text{train}7}^{\text{real}}\}(240)$ 、300 张仿真采集轮廓图像训练集  $\{\mathbf{D}_{\text{train}3}^{\text{simu}}, \mathbf{D}_{\text{train}5}^{\text{simu}}, \mathbf{D}_{\text{train}7}^{\text{simu}}\}(300)$ 。训练图像预处理:训练图像选取随机旋转角度  $\alpha_{\text{rot}} = 0 \sim 30^\circ$ 、随机缩放尺寸  $h_{\text{scale}} = 0.5 \sim 0.8$ <sup>[23]</sup>。

表 1、2 分别为相同测试集  $\{\mathbf{D}_{\text{val}3}^{\text{real}}, \mathbf{D}_{\text{val}5}^{\text{real}}, \mathbf{D}_{\text{val}7}^{\text{real}}\}(60)$  下,应用式(5)校正提升公式后不同骨干 EDE-net 网络与训练集 A、B 类焊缝特征点提取 AP 结果表。表 1 中分别采用 I、120 张实体采集轮廓图像训练集  $\{\mathbf{D}_{\text{train}3}^{\text{real}}, \mathbf{D}_{\text{train}5}^{\text{real}}, \mathbf{D}_{\text{train}7}^{\text{real}}\}(120)$ ,表示有限的实体采集轮廓图像;II、120 张实体采集轮廓图像训练集  $\{\mathbf{D}_{\text{train}3}^{\text{real}}, \mathbf{D}_{\text{train}5}^{\text{real}}, \mathbf{D}_{\text{train}7}^{\text{real}}\}(120) + 300$  张仿真采集轮廓图像训练集  $\{\mathbf{D}_{\text{train}3}^{\text{simu}}, \mathbf{D}_{\text{train}5}^{\text{simu}}, \mathbf{D}_{\text{train}7}^{\text{simu}}\}(300)$ ,表示有限的实体采集轮廓图像+仿真采集轮廓图像;III、240 张实体采集轮廓图像训练集  $\{\mathbf{D}_{\text{train}3}^{\text{real}}, \mathbf{D}_{\text{train}5}^{\text{real}}, \mathbf{D}_{\text{train}7}^{\text{real}}\}(240)$ ,表示较充足的实体采集轮廓图像,AP 综合反映网络特征的提取精度<sup>[16]</sup>。

表 1 不同骨干 EDE-net 网络不同训练集下,应用式(5)校正提升公式网络 A 类纵焊缝特征点提取 AP 结果表  
Table 1 Applying the correction lifting formula of (5) on different backbone EDE-net network and training set A class longitudinal weld feature points extract AP results

| EDE-net 骨干       | 训练集 | AP <sub>0.5</sub> | AP <sub>0.7</sub> | mAP  |
|------------------|-----|-------------------|-------------------|------|
| Resnet50         | I   | 0.49              | 0.37              | 0.34 |
|                  | II  | 0.59              | 0.51              | 0.49 |
|                  | III | 0.64              | 0.60              | 0.58 |
| Resnet152        | I   | 0.73              | 0.63              | 0.60 |
|                  | II  | 0.85              | 0.77              | 0.71 |
|                  | III | 0.86              | 0.78              | 0.71 |
| Inception-Resnet | I   | 0.57              | 0.40              | 0.36 |
|                  | II  | 0.63              | 0.55              | 0.53 |
|                  | III | 0.66              | 0.58              | 0.55 |

可以看出:1)EDE-net 在 III、II 训练集特征点提取效果 AP<sub>0.5</sub>、AP<sub>0.7</sub>、mAP 接近,焊缝轮廓曲线仿真的训练图像增强方法有效;2)所有测试网络提取特征点在进行

特征点校正提升后,AP<sub>0.5</sub>、AP<sub>0.7</sub>、mAP 均有提高,故式(5)提出的校正提升方法可有效提高网络特征点输出精度,是特征点提取重要环节;3)相对 Resnet50、Inception-Resnet 骨干,Resnet152 骨干的 EDE-net 提取效果的相对较佳。因此,骨干为 Resnet152 的 EDE-net 是上述压力容器焊缝特征点提取效果相对较好网络,可应用于后续研究。

表 2 不同骨干 EDE-net 网络不同训练集下,应用式(5)校正提升公式网络 B 类环焊缝特征点提取 AP 结果表  
Table 2 Applying the correction lifting formula of (5) on different backbone EDE-net network and training set class B girth weld feature points extract AP results

| EDE-net 骨干       | 训练集 | AP <sub>0.5</sub> | AP <sub>0.7</sub> | mAP  |
|------------------|-----|-------------------|-------------------|------|
| Resnet50         | I   | 0.45              | 0.36              | 0.31 |
|                  | II  | 0.55              | 0.46              | 0.37 |
|                  | III | 0.56              | 0.46              | 0.38 |
| Resnet152        | I   | 0.68              | 0.59              | 0.50 |
|                  | II  | 0.86              | 0.79              | 0.77 |
|                  | III | 0.87              | 0.79              | 0.78 |
| Inception-Resnet | I   | 0.47              | 0.36              | 0.35 |
|                  | II  | 0.56              | 0.47              | 0.41 |
|                  | III | 0.58              | 0.48              | 0.41 |

将 Resnet152 骨干的 EDE-net 作为教师模型,Resnet50 骨干 EDE-net 为学生模型,对知识蒸馏后<sup>[24]</sup>的骨干为 Resnet50 的 EDE-net 进一步进行结构化通道剪枝处理,结构化通道剪枝不作用于 Resnet50 第一层与最后一层卷积。分别设置剪枝整体压缩率  $CR = 0.8、0.5、0.3$ ,表 3、4 分别为 A、B 类纵、环焊缝结构化通道剪枝、校正提升方法后骨干 CNNs 为 Resnet50 的 EDE-net 特征点提取精度结果。

表 3 A 类纵焊缝结构化剪枝、校正提升方法骨干 CNNs 为 Resnet50 的 EDE-net 特征点提取精度结果  
Table 3 The AP results of the EDE-net feature point extraction of Resnet50 as the backbone CNNs after the structured pruning and correction and lifting methods of class A longitudinal welds

| 整体压缩率  | AP <sub>0.5</sub> | AP <sub>0.7</sub> | mAP  |
|--------|-------------------|-------------------|------|
| CR=1.0 | 0.81              | 0.73              | 0.64 |
| CR=0.8 | 0.79              | 0.71              | 0.63 |
| CR=0.5 | 0.80              | 0.70              | 0.61 |
| CR=0.3 | 0.62              | 0.49              | 0.45 |

表 4 B 类环焊缝结构化剪枝、校正提升方法骨干 CNNs 为 Resnet50 的 EDE-net 特征点提取精度结果

Table 4 The AP results of the EDE-net feature point extraction of Resnet50 as the backbone CNNs after the structured pruning and correction and lifting methods of class B girth welds

| 整体压缩率  | AP <sub>0.5</sub> | AP <sub>0.7</sub> | mAP  |
|--------|-------------------|-------------------|------|
| CR=1.0 | 0.82              | 0.75              | 0.67 |
| CR=0.8 | 0.81              | 0.73              | 0.65 |
| CR=0.5 | 0.80              | 0.72              | 0.62 |
| CR=0.3 | 0.59              | 0.50              | 0.43 |

可以看出,在  $CR=0.8、0.5$  下,模型特征点提取精度相比较于压缩前模型特征点提取精度下降较小,而  $CR=0.3$  时模型特征点提取精度下降较大,特征点提取误差较大,结合精度与模型复杂度考虑,选择  $CR=0.5$  为模型整体压缩率。

表 5 为剪枝前后单张图片特征点提取时间表。单张图片提取时间由原来的 0.31 s 降低到 0.19 s,单张图片提取时间减少 38.7%。

表 5 剪枝前后单张图片特征点提取时间表  
Table 5 Feature point extraction time of a single image before and after pruning

| 参数              | 剪枝前     | 剪枝后     |
|-----------------|---------|---------|
| 输入图像分辨率         | 800×600 | 800×600 |
| 单张图片提取时间/s      | 0.31    | 0.19    |
| 单张图片提取时间提升百分比/% | —       | 38.7    |

针对对接焊缝 5 参数测量工具或仪器检测都难以达到 0.1 mm 精度,经与有关检测部门研讨,专门设计了高精度线切割工艺加工 3 件已知 5 参数的圆筒件模拟焊缝样品,作为测量装置与较高测量仪器测量值比较使用,表 6 为焊缝样品设计参数,图 6 为线切割模拟焊缝样品实物照片,其中图 6(a)、(b) 分别为 A 类纵焊缝样品 0 (有  $h_{re}、l_{width}$  参数)、A 类纵焊缝样品 1 (有  $h_{re}、l_{width}、h_{un\_cut}、h_{peaking}$  参数);图 6(c) 为 B 类环焊缝样品 (有  $h_{re}、l_{width}、h_{un\_cut}、h_{mis\_align}$  参数)。

表 6 焊缝样品设计参数  
Table 6 Weld sample design parameters

| 样品   | $h_{re}$ | $l_{width}$ | $h_{un\_cut}^{left}$ | $h_{un\_cut}^{right}$ | $h_{mis\_align}$ | $h_{peaking}$ |
|------|----------|-------------|----------------------|-----------------------|------------------|---------------|
| 样品 0 | 2.5      | 8.0         | 0                    | 0                     | 0                | 0             |
| 样品 1 | 1.0      | 10.0        | 0.8                  | 0.8                   | 0                | 0.5           |
| 样品 2 | 1.0      | 9.0         | 0.2                  | 0.3                   | 1.0              | 0             |




图 6 线切割焊缝样品实物照片  
Fig. 6 Physical photo of wire cutting weld sample

使用马尔公司 LD260 粗糙度轮廓仪 (表 7 为其技术参数),仪器分辨率 0.8 nm,扫描图 6 的模拟焊缝样品表面形貌,手动选取参数特征点计算的焊缝余高  $h_{re}$ 、宽度  $l_{width}$ 、咬边  $h_{un\_cut}$ 、错边量  $h_{mis\_align}$ 、棱角度  $h_{peaking}$  为约定真值,实现对焊缝样品特征提取与参数测量,表 8 为使用粗糙度轮廓仪测量的焊缝样品质量参数。

表 7 LD260 粗糙度轮廓仪技术参数  
Table 7 LD260 roughness profiler technical parameters

| 分辨率<br>/nm | 测量速度<br>/(mm·s <sup>-1</sup> ) | 测量范围<br>/mm | 粗糙度<br>MPE/% | 轮廓 MPE/ $\mu$ m |
|------------|--------------------------------|-------------|--------------|-----------------|
| 0.8        | 0.1~0.5                        | 0.1~260     | ±2           | ±(1+被测长度/150)   |

表 8 使用粗糙度轮廓仪测量焊缝样品质量参数  
Table 8 Weld sample quality parameters measured with a roughness profiler

| 样品   | $h_{re}$ | $l_{width}$ | $h_{un\_cut}^{left}$ | $h_{un\_cut}^{right}$ | $h_{mis\_align}$ | $h_{peaking}$ |
|------|----------|-------------|----------------------|-----------------------|------------------|---------------|
| 样品 0 | 2.512    | 8.239       | 0                    | 0                     | 0                | 0             |
| 样品 1 | 0.856    | 10.033      | 0.775                | 0.801                 | 0                | 0.500         |
| 样品 2 | 1.005    | 8.802       | 0.157                | 0.399                 | 1.000            | 0             |

图 7 为高精度激光轮廓仪焊缝三维参数检测实验装置结构图,其中图 7(a)、(b) 分别为实验装置内部结构、工作中实验装置。装置采用 Scheimpflug 激光三角测量模型,应用激光器垂直入射、光电探测器倾斜成像传感机理,由激光轮廓传感器、Z 轴方向位移电动滑轨、Y 轴方向位移手动滑轨、装置固定本体与连接件、外接 PC 上位机等组成,这里激光轮廓传感器为满足 Scheimpflug 光路条件相机,在一定景深范围内,被测物在激光线出射方向位移都能在光电探测器上清晰成像,且输出为已经处理的轮廓点集数据,具有较高集成度、准确度、实时传感性能。

高精度激光轮廓仪焊缝三维参数检测实验装置的 A、B 类焊缝检测功能由第三方测试机构按照 GB/T




图 7 高精度激光轮廓仪焊缝三维参数检测实验装置结构图

Fig. 7 Arrangement of actual measurement device for three-dimensional parameter detection of weld seam with high-precision optical wheel library instrument

150—2011《压力容器》进行测试,并给出测试报告(编号:CYD 202100317)<sup>[25]</sup>。表 9 测试报告中焊缝参数测量误差表,测试报告同时显示:装置可以同时测量对接焊缝(A、B 类)焊缝余高、宽度、咬边、错边量、棱角度 5 个参数,5 个参数耗时<0.63 s,测量误差允许误差≤0.08 mm。

表 9 测试报告中焊缝参数测量误差表

Table 9 Weld parameter measurement error table in the test report

| 模拟<br>焊缝 | 轮廓仪评价焊缝<br>参数/mm | 检测装置测量<br>结果/mm                 | 示值误差<br>/mm |        |
|----------|------------------|---------------------------------|-------------|--------|
| 样件 0     | 余高               | 2.512                           | 2.482       | -0.030 |
|          | 宽度               | 8.239                           | 8.250       | +0.011 |
|          | 咬边 1             | 0.005                           | 0           | -0.005 |
|          | 咬边 2             | 0.018                           | 0           | -0.018 |
|          | 错边量              | 0.002                           | 0.053       | +0.051 |
|          | 棱角度              | 0.001                           | 0.021       | +0.020 |
| 样件 1     | 余高               | 0.856                           | 0.872       | +0.016 |
|          | 宽度               | 10.033                          | 10.050      | +0.017 |
|          | 咬边 1             | 0.775                           | 0.704       | -0.071 |
|          | 咬边 2             | 0.801                           | 0.816       | +0.015 |
|          | 错边量              | 0.021                           | 0.047       | +0.026 |
|          | 棱角度              | 0.495                           | 0.475       | -0.020 |
| 样件 2     | 余高               | 1.005                           | 0.950       | -0.055 |
|          | 宽度               | 8.802                           | 8.791       | -0.011 |
|          | 咬边 1             | 0.157                           | 0.167       | +0.010 |
|          | 咬边 2             | 0.399                           | 0.385       | -0.014 |
|          | 错边量              | 1.002                           | 0.975       | -0.027 |
|          | 棱角度              | 0.011                           | 0.042       | +0.031 |
| 结果       |                  | Max   示值误差   = 0.071 mm<0.08 mm |             |        |

6 结 论

本文创新性提出基于深度学习主动视觉压力容器焊缝质量参数检测新方法,该方法通过研究多缺陷共存下焊缝参数计算方法,突破焊缝缺陷参数共存下存在焊缝质量参数难以计算或无法计算理论问题,使仪器可以实现余高 $h_{re}$ 、宽度 $l_{width}$ 、咬边 $h_{un\_cut}$ 、错边量 $h_{mis\_align}$ 、棱角度 $h_{peaking}$ 多参数一次测量;提出 EDE-net 结构设计以及数据增强方法,有效提升参数特征点的提取灵活性、准确性;研究合理深度网络结构化通道剪枝方法,优化网络结构参数,有效地提高压力容器焊缝检测实时性能,真正实现智能化检测仪器的测得出、测得全、测得准、测得快特性功能。

参考文献

[ 1 ] COOK G E, BARNETT R J, ANDERSEN K, et al. Automated visual inspection and interpretation system for weld quality evaluation [ C ]. Proc. of Industry Applications Conference, 1995, 1809-1816.

[ 2 ] XU W, WANG X, ZHANG C. Overview of typical quality problems in nuclear power station steam generator tube to tube sheet welds [ J ]. Hot Working Technology, 2013, 42(13):162-164.

[ 3 ] DING Q, JI J, GAO F, et al. Machine-vision-based defect detection using circular hough transform in laser welding [ C ]. 2016 4th International Conference on Machinery, Materials and Computing Technology, Atlantis Press, 2016.

[ 4 ] GUANGZHI D, TIEQUN C, JIAXIANG X. Research on image resolution in ultrasonic imaging inspection of weld defect [ C ]. Proc. of International Conference on Electronic Measurement and Instruments, 2007: 965-968.

[ 5 ] 廖普,刘桂雄,杨宁祥. 主动视觉压力容器焊缝表面质量参数检测方法研究进展 [ J ]. 激光杂志, 2021, 42(7):1-8.

LIAO P, LIU G X, YANG N X. Research progress on the detection method of main vision pressure vessel weld surface quality parameters [ J ]. Laser Magazine, 2021, 42(7):1-8.

[ 6 ] ALEXANDER T. DeepPose: Human pose estimation via deep neural networks [ C ]. IEEE, 2013, DOI: 10.1109/CVPR.2014.214.

[ 7 ] CHEN Y, WANG Z, PENG Y, et al. Cascaded pyramid network for multi-person pose estimation [ C ]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2017.

- [ 8 ] CHOUDHARY T, MISHRA V, GOSWAMI A, et al. A comprehensive survey on model compression and acceleration[J]. Artificial Intelligence Review, 2020, 53(7):5113-5155.
- [ 9 ] HAN S, POOL J, TRAN J, et al. Learning both weights and connections for efficient neural networks [J]. Advances in Neural Information Processing Systems, 2015. DOI:10.48550/arXiv.1506.02626.
- [10] LIU Z, LI J, SHEN Z, et al. Learning efficient convolutional networks through network slimming [J]. 2017 IEEE International Conference on Computer Vision (ICCV), 2017:2755-2763.
- [11] ZEHAO H, NAIYAN W. Data-driven sparse structure selection for deep neural networks[J]. Computer Vision-ECCV 2018, 15th European Conference. Proceedings: Lecture Notes in Computer Science (LNCS 11220), 2018:317-334.
- [12] DENG C. Accelerate CNNs from three dimensions: A comprehensive pruning framework [C]. International Conference on Machine Learning, PMLR, 2020.
- [13] 国家质检总局. 压力容器:GB 150—2011 [S]. 北京:中国质检出版社,2011.  
General Administration of Quality Supervision, Inspection and Quarantine of the People's Republic of China. Pressure Vessel: GB 150—2011 [S]. Beijing: China Quality Inspection Press, 2011.
- [14] LIAO P, LIU G X, YANG N X. Method for inspection the surface quality parameters of pressure vessel welds[C]. 2nd International Conference on Cloud Computing and Mechatronic Engineering, 2022.
- [15] LIAO P, LIU G, YANG N X. Estimation of arc welding pressure pipeline weld peaking parameters based on data prediction[J]. Mathematical Problems in Engineering, 2021:1-12.
- [16] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. Computer Science, 2014 :1409. 1556.
- [17] JIAN S, KAIMING H, SHAOQING R, et al. Deep residual learning for image recognition [J]. ArXiv Preprint,2015, ArXiv :151203385.
- [18] LIAO P, LIU G X. Pressure vessel-oriented visual inspection method based on deep learning[J]. Plos One, 2022, 17(5): e0267743.
- [19] 钱梦薇, 过弋. 融合偏置深度学习的距离分解 Top-N 推荐算法[J]. 计算机科学, 2021, 48(9):1-7.  
QIAN M W, GUO G. Distance decomposition Top-N recommendation algorithm with fusion bias deep learning[J]. Computer Science, 2021, 48(9):1-7.
- [20] 徐晓,蒋志翔,张杨. 基于通道剪枝和量化的卷积神经网络压缩方法[J]. 计算机工程与设计, 2021, 42(10):2860-2866.  
XU X, JIANG ZH X, ZHANG Y. Convolutional neural network compression method based on channel pruning and quantization[J]. Computer Engineering and Design, 2021,42(10):2860-2866.
- [21] 段秉环, 文鹏程, 李鹏. 面向嵌入式应用的深度神经网络压缩方法研究[J]. 航空计算技术, 2018, 48(5):50-53.  
DUAN B H, WEN P CH, LI P. Research on deep neural network compression method for embedded applications[J]. Aeronautical Computing Technology, 2018, 48(5):50-53.
- [22] 李丹, 王慢慢, 刘俊德. 基于轻量级卷积神经网络的带钢表面缺陷识别[J]. 仪器仪表学报, 2022, 43(3):240-248.  
LI D, WANG M M, LI J D. Strip surface defect recognition based on lightweight convolutional neural network[J]. Chinese Journal of Scientific Instrument, 2022, 43(3):240-248.
- [23] KEVIN M. PyTorch metric learning[J]. ArXiv Preprint, 2020, ArXiv: 200809164.
- [24] 廖普, 刘桂雄, 杨宁祥. 基于知识蒸馏 KD 压力容器焊缝参数特征点提取实时性提升方法[J]. 激光杂志, 2023,44(3):69-74.  
LIAO P, LIU G X, YANG N X. Extraction of parameter feature points of pressure vessel welds based on knowledge distillation real-time improvement method[J]. Laser Magazine, 2023,44(3):69-74.
- [25] 广东省珠海市质量计量监督检测所. 特种设备焊缝表面轮廓检测装置[R]. CYD202100317.  
Guangdong Zhuhai Supervision Testing Institute of Quality and Metrology. Weld surface profile detection device for special equipment[R]. CYD202100317.

## 作者简介



刘桂雄(通信作者),1990 年于重庆大学获得学士学位,1995 年于重庆大学获得博士学位,现为华南理工大学教授,主要研究方向为制造工程智能化检测及仪器。

E-mail: megxliu@scut.edu.cn

**Liu Guixiong** (Corresponding author)

received his B.Sc. degree from Chongqing University in 1990, and received his Ph.D. degree from Chongqing University in 1995. He is currently a professor at South China University of Technology. His main research interest is intelligent testing and instruments for manufacturing engineering.