

改进 FasterRCNN 模型的布氏硬度检测方法

周如辰, 游昌壕, 潘永东

(同济大学 航空航天与力学学院, 上海 200092)

摘要: 自动提取布氏压痕轮廓是提高布氏硬度检测效率的关键一步, 针对传统机器视觉算法提取布氏压痕轮廓算法的不足, 通过 FasterRCNN 模型实现了布氏硬度压痕直径的自动化检测; 针对检测布氏硬度压痕圆的特点, 提出对 FasterRCNN 模型的改进; 在 classification 网络中的边框回归损失函数中加入预测检测框的长与宽的方差, 在改进的边框回归函数优化目标修改为真实检测框与预测检测框差距最小且预测检测框宽与高之间差距最小, 使得基于改进的 FasterRCNN 模型布氏硬度检测能够提供更加准确的目标预测检测框, 取得更精准检测效果; 同时引入数据增强的方法扩充有效数据大小; 实验结果表明, 基于 FasterRCNN 的布氏硬度模型检测方法适用于锈蚀和光滑金属表面工况; 改进的 FasterRCNN 网络模型准确率为 97.08%, 较原模型提升 0.73%, 归一化均方误差 (nMSE) 为 0.001 226, 较原模型降低 40.31%, 改进的效果明显, 并弥补机器视觉算法提取压痕轮廓的不足。

关键词: FasterRCNN; 布氏硬度; 边框回归; 压痕提取; 计算机视觉

Measuring Brinell Hardness by Improving FasterRCNN Model

ZHOU Ruchen, YOU Changhao, PAN Yongdong

(School of Aerospace Engineering and Applied Mechanics, Tongji University, Shanghai 200092, China)

Abstract: Automatic extraction of Brinell indentation contour is a key step to improve the efficiency of Brinell hardness detection. In order to solve the shortcomings of extracting Brinell indentation contour by traditional machine vision algorithm, an automatic detection of brinell hardness indentation diameter is realized by FasterRCNN model. According to the characteristics of Brinell hardness indentation circle detection, an improved FasterRCNN model is proposed. The variance of length and width of the predicted detection frame is added into the frame regression loss function in the Classification network, and the optimization objective of the improved frame regression function is modified whose goal is to minimize both the gap between the real detection frame and the predicted detection frame and the gap between the width and height of the predicted detection frame. The brinell hardness test based on the improved FasterRCNN model can provide more accurate target prediction detection frame and achieve more accurate detection effect. At the same time, the data enhancement method is introduced to expand the effective data size. The result shows that the Brinell hardness model detection method based on FasterRCNN is suitable for corroded and smooth metal surfaces. Also, the accuracy of the improved FasterRCNN network model is 97.08%, which is 0.73% higher than the original model, and the normalized mean square error (nMSE) is 0.001 226, which is 40.31% lower than the original model. The improving effect is obvious, and make up for the deficiency of particle swarm dynamic contour model (Snake model).

Keywords: FasterRCNN; brinell hardness; box regression; indentation extraction; machine vision

0 引言

硬度是反映材料力学性能的基本指标^[1]。布氏硬度法是通过加载一定大小的载荷力将硬质钢球压入待测物体表面^[2], 通过压痕直径换算试件的硬度。因为该方法的压痕较大, 相较于里氏硬度法有更高的准确性。

布氏硬度检测方法数值稳定, 但是现有方法^[3]绝大多数都是在 20 倍显微镜通过人工读取压痕直径, 然后人工对照直径硬度换算表格来确定待测物体硬度值, 该方法在工厂生产工况下检测效率低下, 且有较大检验误差。

针对布氏硬度法检测^[4]过程中需要使用光学仪器人工找点检测压痕直径效率低的情况, 李和平^[5]提出根据压痕

深度计算出压痕直径及布氏硬度, 方法并没有经过广泛验证, 且设备长期使用后精度可能会丢失。西北工业大学^[6]提供了一种硬度块压痕直径测量方法及装置, 通过图像处理, 最后采用最小二乘法拟合提取压痕拟合直径得到布氏硬度。单忠德^[7]等根据机器视觉^[8]相关理论提出了基于粒子群动态轮廓模型 (Snake 模型^[9]) 的压痕轮廓提取算法, 并通过引入压痕直径标定系数, 解决了视觉测量中的压痕直径像素与压痕物理直径的换算关系, 并对直径标定系数进行最小二乘法拟合, 提高了测量精度。但他们的测量大多数是在图像轮廓很清晰的条件下进行的, 对于工件表面反光不佳, 表面锈蚀导致压痕轮廓清晰度降低的图像, 该算

收稿日期: 2021-12-15; 修回日期: 2022-01-26。

作者简介: 周如辰(1998-), 男, 上海人, 硕士研究生, 主要从事航空航天无损检测和深度学习方向的研究。

通讯作者: 潘永东(1967-), 男, 江苏昆山人, 博士研究生, 教授, 博士生导师, 主要从事无损健康检测和超声无损检测等方向的研究。

引用格式: 周如辰, 游昌壕, 潘永东. 改进 FasterRCNN 模型的布氏硬度检测方法[J]. 计算机测量与控制, 2022, 30(6): 72-78, 83.

法会失效, 本文尝试用该算法检测锈蚀金属表面的布氏压痕, 识别效果如图 1 所示, 可见该算法针对压痕轮廓清晰的图片有较好的效果, 针对压痕轮廓不清晰的情况则效果不佳。

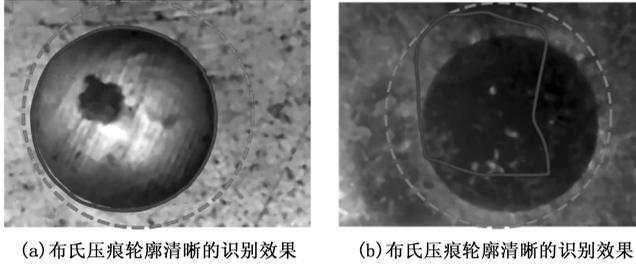


图 1 使用改进的 snake 算法检测布氏硬度压痕的效果图示例

近年来, 深度学习在机器视觉^[10]领域兴起。深度学习通过建立神经网络从图片中提取有用的信息, 通过不断优化损失函数的方式训练, 最后得到特征与目标之间映射的深度学习模型^[11]。FasterRCNN^[12]网络作为目标检测^[13]方法的一种, 在数据标注过程中, 除了标注类别之外, 还通过标注矩形框标注了目标物体。在矩形框内的属于目标物体的正例部分, 在矩形框外的属于目标物体外的负例部分。因此使用该网络进行训练, 不仅可以识别目标物体, 并且可以得到目标在图像中所处的位置和大小。本文目的是完成布氏硬度压痕圆识别, 计算布氏硬度压痕圆直径两个功能, 通过 FasterRCNN 网络可以完成布氏硬度压痕圆识别, 通过布氏硬度压痕圆定位框大小位置计算布氏硬度压痕圆直径两个功能, 解决布氏硬度法测量布氏硬度压痕直径大小的问题。针对布氏硬度压痕特点, 适当对 FasterRCNN 网络进行改进可以提高布氏硬度压痕圆直径的测量精度^[14]。本文首次提出通过 FasterRCNN 网络检测布氏硬度压痕, 针对布氏压痕特点改进 FasterRCNN 网络, 可以在光滑或锈蚀金属表面自动^[15]提取布氏硬度压痕轮廓并提高布氏硬度压痕圆直径的测量精度, 弥补传统机器视觉算法提取压痕轮廓的不足。

1 数据获取

1.1 数据采集

基于 FasterRCNN 的布氏硬度法采用布氏硬度标准测试块^[16], 选取 5 种型号 200HBW10/3000, 300HBW10/3000, 400HBW10/3000, 500HBW10/3000, 600HBW10/3000。每种型号硬度块选取一块, 对于每个硬度块^[17], 本文对其正面涂油保存, 反面不涂油保护, 在潮湿环境下使得试块正面呈现锈蚀斑点, 另一面保持光滑平整。200HBW10/3000 含义是指在 14 710 N (15 000 kgf) 的试验载荷作用下, 将直径为 10 mm 的淬硬钢球压入试块, 保持 10~15 s 时, 测得的布氏硬度值为 200。本文采用 14 710 (15 000 kgf) 的试验载荷压入钢球^[18], 保持时间 10~15 s, 对每种型号试块锈蚀面和非锈蚀面各留 10 个压痕。本文采用 1 000 倍 USB 电子放大镜, 对每个压痕处于镜头中不同

位置拍摄 10 张照片, 共计 1 000 张照片。同时采集不存在布氏硬度压痕的照片 200 张, 提取存储格式为 Jpg, 分辨率大小为 640 × 480。

1.2 数据标注

对不包含压痕圆的 200 张图片数据不进行矩形框标注, 作为数据集中的正常类图片, 作对照组。

针对数据集中存在压痕圆的图片, 本文通过矩形框标注压痕圆在图片中的直径与矩形框位置, 运用三点求圆法得到矩形框所处的位置与直径。

数据标注过程前, 手动标注出照片中分布于压痕边缘的 15 个点, 从 15 个点中任意选取 3 个点能得到 105 组圆的直径数据和中心位置。在每组测量 (第 m 组) 过程中, 选取的 3 个点在图像坐标系中的像素坐标为 (x_{mi}, y_{mi}) , (x_{mj}, y_{mj}) , (x_{mk}, y_{mk}) , 第 m 组测量测得圆的半径 r_m , 中心位置 (x_m, y_m) , 那么有:

$$\begin{cases} (x_m - x_{mi})^2 + (y_m - y_{mi})^2 = r_m^2 \\ (x_m - x_{mj})^2 + (y_m - y_{mj})^2 = r_m^2 \\ (x_m - x_{mk})^2 + (y_m - y_{mk})^2 = r_m^2 \end{cases} \quad (1)$$

式 (1) 的第一式和第二式相减, 第一式和第三式相减可得:

$$\begin{cases} (x_{mi} - x_{mj})x_m + (y_{mi} - y_{mj})y_m = \frac{(x_{mi}^2 - x_{mj}^2) + (y_{mi}^2 - y_{mj}^2)}{2} \\ (x_{mi} - x_{mk})x_m + (y_{mi} - y_{mk})y_m = \frac{(x_{mi}^2 - x_{mk}^2) + (y_{mi}^2 - y_{mk}^2)}{2} \end{cases} \quad (2)$$

那么:

$$\begin{cases} x_m = -\frac{de - bf}{bc - ad} \\ y_m = -\frac{af - ce}{bc - ad} \\ r_m = \sqrt{\left(-\frac{de - bf}{bc - ad} - x_{mi}\right)^2 + \left(-\frac{af - ce}{bc - ad} - y_{mi}\right)^2} \end{cases} \quad (3)$$

其中:

$$\begin{cases} a = x_{mi} - x_{mj} \\ b = y_{mi} - y_{mj} \\ c = x_{mi} - x_{mk} \\ d = x_{mi} - x_{mk} \\ e = \frac{(x_{mi}^2 - x_{mj}^2) + (y_{mi}^2 - y_{mj}^2)}{2} \\ f = \frac{(x_{mi}^2 - x_{mk}^2) + (y_{mi}^2 - y_{mk}^2)}{2} \end{cases} \quad (4)$$

可见, 通过第 m 组测量得到的像素坐标 (x_{mi}, y_{mi}) , (x_{mj}, y_{mj}) , (x_{mk}, y_{mk}) 可求得第 m 组圆的半径 r_m , 中心位置 (x_m, y_m) 。本文求取 105 组圆的半径 r_m 及中心位置 (x_m, y_m) 的平均值作为该张照片压痕圆的真实半径 r_0 (此处的直径指的是图片中圆的直径对应的像素值大小, 本文下面出现的直径指的此含义) 及中心位置 (x_0, y_0) , 该关系如式 (5) 所示:

$$\begin{cases} x_0 = \frac{\sum_{m=1}^{105} x_m}{105} \\ y_0 = \frac{\sum_{m=1}^{105} y_m}{105} \\ r_0 = \frac{\sum_{m=1}^{105} r_m}{105} \end{cases} \quad (5)$$

在图片标注过程中，通过确定顶点坐标 (x_1, y_1) , (x_2, y_2) , (x_3, y_3) , (x_4, y_4) 来标注矩形框，标注过程如图 2 所示。矩形框与图像中的压痕圆相切，故顶点坐标可依据压痕圆的半径 r_0 ，中心位置 (x_0, y_0) 给出，该关系如式 (6) 所示：

$$\begin{cases} x_1 = x_m - r \\ y_1 = y_m - r \\ x_2 = x_m + r \\ y_2 = y_m - r \\ x_3 = x_m - r \\ y_3 = y_m + r \\ x_4 = x_m + r \\ y_4 = y_m + r \end{cases} \quad (6)$$

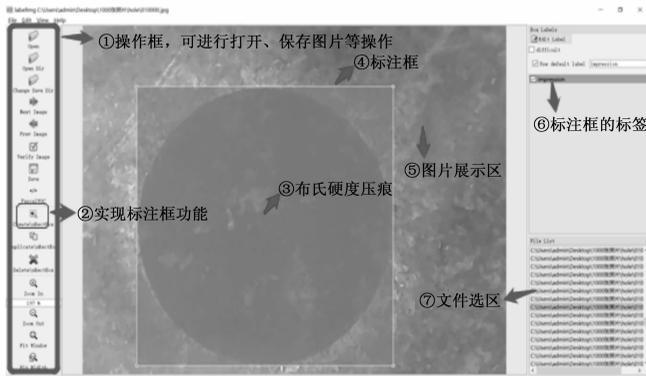


图 2 图像数据的标注过程

数据集实际采集 1 200 张图片，其中 200 张图片不含压痕圆，没有检测框，作为数据集的负例部分。在 1 000 张存在布氏硬度压痕的照片中，布氏硬度压痕的位置，大小和背景都存在差异，可适用于本实验的训练目标。本文提出的基于布氏硬度检测的 FasterRCNN 模型为单类别目标检测，数据量少会导致泛化能力差，模型过拟合等问题，因此需要进行数据增强。数据增强主要是对采集到的图片采取左右翻折，上下翻折处理，同时针对实际工况中的不同光照条件，对模型进行随机调整亮度对比度处理，数据增强示例如图 3 所示，经过数据增强后的数据集总共包含 4 800 张图片。由于数据集是按批次送入神经网络中训练，数据量的增长并不会增加模型的训练运算量，显存占用量。数据增强的优点是解决模型过拟合^[19]，泛化能力差的缺点，使得模型的鲁棒性增强，同时提高模型在不同亮度条件下的检测能力。

经过增强的数据集包含 4 800 张照片。本文对照片标注

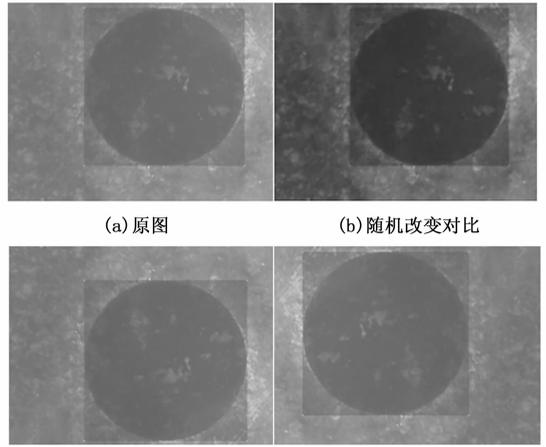


图 3 训练数据集数据增强的 3 种扩充方法

类别为压痕，并标注矩形边框，同时以 PASCAL VOC 的格式保存数据集^[20]。

2 改进 FasterRCNN 模型

2.1 FasterRCNN 神经网络模型

FasterRCNN 是一种端到端目标检测算法，通过卷积运算提取特征，对候选框大小及目标类型进行回归达到实时检测要求。FasterRCNN 主要由卷积层，RPN 网络，RoI-Pooling 层和分类层 4 个部分组成，如图 4 所示。

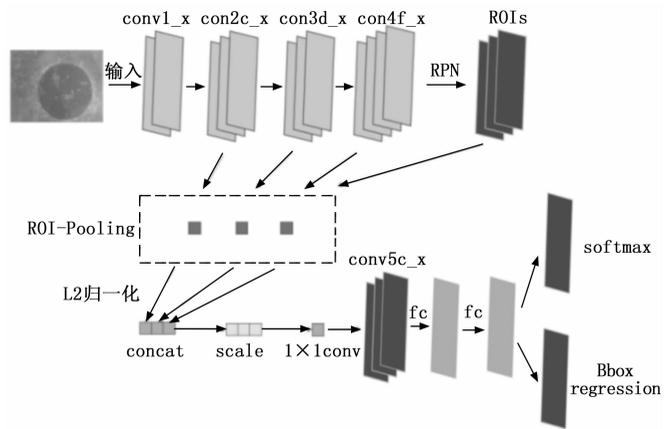


图 4 原始的 FasterRCNN 模型

1) 图像特征选取网络：FasterRCNN 基于卷积神经网络^[21] (VGG16^[22], ResNet50^[23]) 提取图片中的特征矩阵，该特征矩阵将被作为后续 RPN 层和全连接层^[24]的输入。

2) RPN 网络 (图像特征选取网络)：RPN 网络 (Region Proposal Networks) 的作用是生成目标检测候选区域。该层通过 softmax 层判断锚框属于前景或背景并标记，再利用边框回归调整候选锚框的大小，让目标检测候选区域更准确，更贴近真实的正例检测区域。

3) Roi Pooling 层 (感兴趣区域池化层)：Roi Pooling 层将 RPN 网络输出的特征和 RPN 网络输出的目标检测候选区域作为输入，提取其中的综合信息得到感兴趣区域，

将感兴趣区域池化为固定尺寸的特征图。

4) Classification 层 (分类层): Classification 层利用 Roi Pooling 层输出的特征矩阵进行两个工作: 1) 判断候选区域的类别; 2) 再次进行边框回归得到检测框的准确位置, 让目标检测候选区域更准确, 更贴近真实的正例检测区域。

2.2 改进边框回归

在图像坐标系中, 一个矩形边框可以用其中心位置坐标 (a, b) 及矩形边框的宽 w 与高 h 表示。故本文采用矩形边框的中心位置坐标及边框的宽与高 (a, b, w, h) 来定义矩形边框。

基于 FasterRCNN 的布氏硬度检测方法通过 FasterRCNN 模型实现布氏压痕圆边缘的提取, 目标检测框内为图片正例部分, 即模型认为存在布氏硬度压痕的区域, 目标检测框外为图片负例部分, 即模型认为不存在布氏硬度压痕的区域。目标检测框为最大覆盖存在布氏硬度压痕的矩形区域, 布氏硬度压痕的形状为圆形, 因此布氏压痕圆会相切于目标检测框。进一步, 本文通过获取 FasterRCNN 模型输出的检测边框的宽 w_{output} 与高 h_{output} 来计算压痕圆^[25]的直径 d , 该关系如式 (7) 所示:

$$d = \frac{(w_{\text{output}} + h_{\text{output}})}{2} \quad (7)$$

在 FasterRCNN 网络中, RPN 网络会先经过 3×3 的卷积运算, 然后网络分为两条支路。第一条路线用来判断候选框是前景还是背景, 它先把输入的候选框特征矩阵映射到一维向量, 然后采用 softmax 函数来判断候选框是前景还是背景, 然后把它恢复为二维特征矩阵。第二条路线用来确定候选框的位置, 通过边框回归 (bounding box regression) 实现。经过两路计算结束后, 挑选出前景候选框, 并利用计算得到候选框准确位置, 生成特征子图。同时在最后的 classification 层 (分类层) 会再次利用到边框回归 (bounding box regression) 用于回归更加精确的目标检测框。

在 RPN 网络中, RPN 对于锚框的设置为默认的 9 种 (默认为 3 种尺度 $\{32^2, 64^2, 128^2\}$, 3 种宽高比 $\{1:2, 1:1, 2:1\}$)。如图 5 (a) 所示, 已知黑色为当前的选区, 即锚框 (在 RPN 网络中设置), 白色代表真实的选区, 当前的选区可以大概率选择出目标物, 但是离真实选区中的真实位置和形状仍然还有较大误差。

在 classification 层中, Classification 层利用 Roi Pooling 层输出的特征矩阵的信息, 得到候选区域的位置。如图 5 (b) 所示, 黑色为候选区域的位置, 白色代表真实的窗口, 经过 RPN 网络和 Roi Pooling 层输出的候选区域已经可以覆盖大部分目标正例区域, 但是离真实检测框的位置和形状仍然还有调整空间。

在 classification 层中的边框回归 (bounding box regression) 的目标是寻找一种映射关系, 该关系使得候选区域 (Region proposal) (a_o, b_o, w_o, h_o) A 经过映射 F 得到一个跟

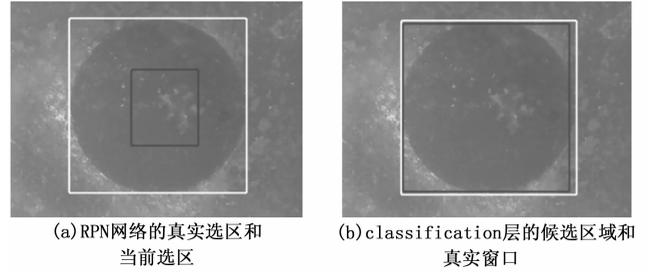


图 5 图像的真实选区和当前选区

真实窗口 (a_t, b_t, w_t, h_t) G 更接近的回归窗口 $G'(a'_o, b'_o, w'_o, h'_o)$, 关系如式 (8) 所示:

$$(a'_o, b'_o, w'_o, h'_o) = F(a_o, b_o, w_o, h_o) \quad (8)$$

在具体的边框回归过程中, 主要进行如下变换:

1) 先对候选区域 A 的中心位置进行平移变换 $(\Delta x, \Delta y)$, 该关系如式 (9) 所示:

$$\begin{aligned} \Delta x &= w_o d_x(a_o, b_o, w_o, h_o) \\ \Delta y &= h_o d_y(a_o, b_o, w_o, h_o) \end{aligned} \quad (9)$$

其中: d_x, d_y 为 FasterRCNN 模型在平移变换时的映射, 映射关系需要通过模型训练学习。

经过平移变换后的回归窗口 G' 的中心位置与候选区域 A 的中心位置之间的关系如式 (10) 所示:

$$\begin{aligned} a'_o &= w_o d_x(a_o, b_o, w_o, h_o) + a_o \\ b'_o &= h_o d_y(a_o, b_o, w_o, h_o) + b'_o \end{aligned} \quad (10)$$

2) 再对检测框进行尺度缩放 (A_w, A_h) , 该关系如式 (11) 所示:

$$\begin{aligned} A_w &= \exp(d_w(a_o, b_o, w_o, h_o)) \\ A_h &= \exp(d_h(a_o, b_o, w_o, h_o)) \end{aligned} \quad (11)$$

其中: d_w, d_h 为 FasterRCNN 模型在尺度缩放时的映射, 映射关系需要通过模型训练学习。

经过尺度缩放后的回归窗口 G' 的宽和高与候选区域 A 的中心位置之间的关系如式 (12) 所示:

$$\begin{aligned} w'_o &= w_o \exp(d_w(a_o, b_o, w_o, h_o)) \\ h'_o &= h_o \exp(d_h(a_o, b_o, w_o, h_o)) \end{aligned} \quad (12)$$

真实窗口 G 与候选区域 A 之间的真实平移变换值 (t_x, t_y) 和真实尺度变换值 (t_w, t_h) 如该关系如式 (13) 所示:

$$\begin{aligned} t_x &= \frac{a_t - a_o}{w_o} \\ t_y &= \frac{b_t - b_o}{h_o} \\ t_w &= \ln\left(\frac{w_t}{w_o}\right) \\ t_h &= \ln\left(\frac{h_t}{h_o}\right) \end{aligned} \quad (13)$$

将真实平移变换值 (t_x, t_y) 和真实尺度变换值 (t_w, t_h) 定义为真实值 $t_* = (t_x, t_y, t_w, t_h)$

相应的, 本文将预测平移变换值 (d_x, d_y) 和预测尺度变换值 (d_w, d_h) 定义为预测值 $d_* = (d_x, d_y, d_w, d_h)$, 目标函数如式 (14) 所示:

$$d_* = \omega_*^T P \tag{14}$$

其中： $p = (a_o, b_o, \omega_o, h_o)$ 作为输入特征向量， ω_* 为要学习的参数（* 代表 x, y, w, h ，每个变换对应一个目标函数）。

如图 6 所示，当候选区域 A 与真实窗口 G 之间位置相差较小，可认为是一种线性变化，故对其采用线性回归模型建模。在传统的 FasterRCNN 中采用 smooth L1 loss 作为边框回归 (bounding box regression) 的损失函数，smooth L1 函数公式为：

$$smooth_{L1}(x) = \begin{cases} 0.5x^2, & \text{if } |x| < 1 \\ |x| - 0.5, & \text{otherwise} \end{cases} \tag{15}$$

在 classification 层中的边框回归的目的是使得预测值 d_* 与真实值 t_* （* 代表 x, y, w, h ，每个变换代表一个真实值）之间差距最小，因此损失函数 Loss 定义为：

$$Loss = \sum_{i=1}^N (t_*^i - \omega_*^T P^i)^2 \tag{16}$$

函数优化目标 M_* 定义为：

$$M_* = \operatorname{argmin} (\omega_* (\sum_{i=1}^N (t_*^i - \omega_*^T P^i)^2 + \lambda \|\omega_*\|^2)) \tag{17}$$

根据式 (7) 可知，基于 FasterRCNN 的布氏硬度检测方法测量压痕直径 d 是通过获取预测检测框（即回归窗口 G' ）的宽与高，求出预测检测框（即回归窗口 G' ）的宽与高的平均值得到的。考虑到完全相切于压痕圆的真实检测框应为正方形，具有四边边长相同的性质，应在损失函数及函数优化目标中加以相关约束，尽可能维持预测检测框的形状为正方形，提高模型检测压痕圆直径精度。但是改进前的边框回归 (bounding box regression) 函数优化目标仅是预测值 d_* 与真实值 t_* 之间差距最小，并未限制预测检测框（即回归窗口 G' ）的宽 w'_* 与高 h'_* 相同。本文针对上述缺点，基于布氏硬度检测的特性，提出基于 FasterRCNN 模型检测布氏硬度方法的改进。本文通过在 FasterRCNN 的 classification 层中，调整边框回归 (bounding box regression) 的损失函数和函数优化目标，在边框回归 (bounding box regression) 的损失函数和函数优化目标中加入预测检测框宽与高相等的约束来改进 FasterRCNN 模型。

在传统边框回归过程中，边框回归先对候选区域 A 的中心位置进行平移变换，再对候选区域 A 进行尺度缩放，得到预测的检测框，通过最小化损失函数让预测的检测框接近真实的检测框。针对布氏硬度检测，在让预测的检测框接近真实的检测框的基础上，应该使得预测检测框具有四边相等的性质，本文通过在改进的损失函数中加入对于经过平移变换 ($\Delta x, \Delta y$) 和尺度缩放 (A_w, A_h) 的预测检测框的高 h'_* 与宽 w'_* 的方差，在改进的函数优化目标中维持预测值 d_* 与真实值 t_* 之间差距最小的同时，加入预测检测框（即回归窗口 G' ）宽 w'_* 与高 h'_* 之间差距最小这一目标，预测检测框（即回归窗口 G' ）的宽 w'_* 与高 h'_* 。如式 (12) 所示，改进后的损失函数 $Loss'$ 如式 (18)

所示：

$$Loss' = \sum_{i=1}^N (t_*^i - \omega_*^T P^i)^2 + \sum_{i=1}^N (P^i \begin{bmatrix} 0 \\ 0 \\ 1 \\ 0 \end{bmatrix} \exp(\omega_w^T P^i) - P^i \begin{bmatrix} 0 \\ 0 \\ 0 \\ 1 \end{bmatrix} \exp(\omega_h^T P^i))^2 \tag{18}$$

改进后的函数优化目标 M'_* 。如式 (19) 所示：

$$M'_* = \operatorname{argmin} [\omega_* (\sum_{i=1}^N (t_*^i - \omega_*^T P^i)^2 + \sum_{i=1}^N (P^i \begin{bmatrix} 0 \\ 0 \\ 1 \\ 0 \end{bmatrix} \exp(\omega_w^T P^i) - P^i \begin{bmatrix} 0 \\ 0 \\ 0 \\ 1 \end{bmatrix} \exp(\omega_h^T P^i))^2 + \lambda \|\omega_*\|^2)] \tag{19}$$

通过改进边框回归 (bounding box regression) 的损失函数，能够使得改进的 FasterRCNN 模型在检测布氏硬度压痕时，预测的检测框的宽与高之间差距最小。基于改进 FasterRCNN 的布氏硬度检测能够在保留 FasterRCNN 的 classification 层中的边框回归预测值 d_* 与真实值 t_* 之间差距最小的同时，使得预测的检测框形状最贴近正方形，更符合布氏硬度压痕圆的特点，使得模型在布氏硬度的检测中，表现出更优的检测精度和更好的检测效果，改进后的 FasterRCNN 模型网络如图 6 所示。

3 实验结果与分析

3.1 实验环境

本实验的硬件采用 Intel Core i7-8750H CPU @ 2.20GHz 八核处理器，LITEON CV8-8E128-11 SATA 128GB 固态硬盘，NVIDIA GeForce GTX 1060 with Max-Q Design 显卡，操作系统环境采用 Ubuntu16.04，采用 Tensorflow-gpu 深度学习框架，Pycharm 编译环境。

3.2 实验参数

本实验将数据集按训练集，验证集，测试集按 7 : 1 : 2 的比例进行划分。在实验中，传统 FasterRCNN 模型采用的模型主干网络采用 ResNet50，使用的最终模型为 Res-

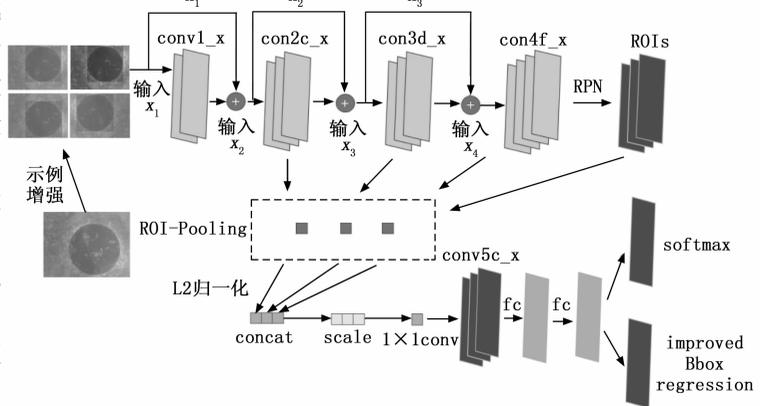


图 6 改进后的 FasterRCNN 模型

Net50+RPN 网络+ROI Pooling+Classification 层。改进的 FasterRCNN 模型采用的模型主干网络采用 ResNet50, 使用的最终模型为 ResNet50+RPN 网络+ROI Pooling+改进的 Classification 层。超参数的设置在实验中经过不断优化调整最终设置为: 训练步数 20 000 步, RPN 网络采取反向传播和随机梯度下降进行端到端训练, 优化器动量为 0.9, 权重衰减为 0.000 5, 学习率 learning rate 设置为 0.000 1, 当训练步数超过 10 000 步时, 学习率采用固定步长衰减, 权值衰减 gamma 为 0.1, 步长为 step size100。

3.3 实验评价指标

为了验证改进的 FasterRCNN 模型的有效性以及基于 FasterRCNN 模型的布氏硬度检测方法的检测能力, 本文评价模型的指标主要分为两部分: 第一部分是去衡量模型正确检测压痕圆的能力, 第二部分是去衡量模型推导出压痕圆直径的检测精度。

第一部分通过计算模型准确率 *Accuracy* 进行评价, 评价指标如下:

总样本数为 *S*, 图片含有布氏压痕且模型预测为布氏压痕及图片不含有布氏压痕且模型预测不含有布氏压痕的样本总数为 *P*, 即模型预测正确的样本总数, 得到准确率 *Accuracy* 公式如式 (20) 所示:

$$Accuracy = \frac{P}{S} \quad (20)$$

根据式 (20) 可知, 当模型准确率 *Accuracy* 指标越大时, 表明模型识别压痕圆的能力越高。

第二部分通过计算模型归一化均方误差 *nMSE* 进行评价, 评价指标如下:

评价该指标时, 在检测正确且检出布氏硬度压痕的图片中, 通过将式 (5) 计算得出的压痕真实直径 r_0 与式 (7) 计算得出的通过模型输出的压痕直径 d_i 进行比较, 得到归一化均方误差 *nMSE* 公式如式 (21) 所示:

$$\begin{aligned} MSE &= \frac{1}{m} \sum_{i=1}^m \left(r_0 - \frac{d_i}{2} \right)^2 \\ VAR &= \frac{1}{m} \sum_{i=1}^m \left(r_0 - \frac{1}{m} \sum_{i=1}^m \left(\frac{d_i}{2} \right) \right)^2 \\ nMSE &= \frac{1}{m} \frac{MSE}{VAR} \end{aligned} \quad (21)$$

根据式 (21) 可知, 当归一化均方误差 *nMSE* 指标越小时, 表明模型检测压痕直径的准确度越高。

3.4 实验结果对比

实验中使用本文 1.2 节中的数据, 为了满足布氏硬度常见工况下的检测, 提高数据样本的多样性, 提取了分别在锈蚀表面以及非锈蚀表面情况下含有布氏硬度压痕的图片 (如图 7 (a), (b) 所示), 锈蚀表面图片的布氏硬度压痕边缘较为模糊, 而非锈蚀表面图片的布氏硬度压痕边缘较为清晰。同时添加一定负例, 负例中不存在布氏硬度压痕, 包含锈蚀表面以及非锈蚀表面情况下的试块表面图片 (如图 7 (c), 7 (d) 所示), 进行数据增强进一步丰富样本供模型学习。数据集共 4 800 张图片, 训练集, 验证

集, 测试集的数量分别为 3 260 张, 480 张, 960 张。

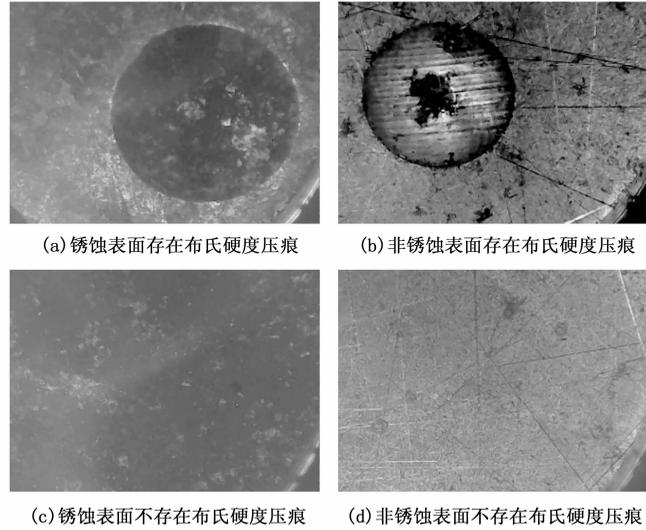


图 7 数据集部分展示

本实验采用模型准确率 *Accuracy*, 模型归一化均方误差 *nMSE* 两个指标对数据集中划分出的测试集部分进行指标评估, 对比基于改进的 FasterRCNN 与传统的 FasterRCNN 模型在本文自建的压痕圆数据集中的识别效果, 具体结果见表 1 所示。

表 1 FasterRCNN 模型与改进的 FasterRCNN 模型检测指标对比

模型名称	FasterRCNN 模型	改进的 FasterRCNN 模型
准确率(<i>Accuracy</i>)/%	96.35	97.08
归一化均方误差(<i>nMSE</i>)	0.002 054	0.001 226

从表 1 中可看出, 改进的 FasterRCNN 模型的准确率 *Accuracy* 为 97.08%, 比传统的 FasterRCNN 模型的准确率 *Accuracy* 提升 0.73%。综上所述, 改进的 FasterRCNN 模型对于检测图像区域内是否存在压痕圆有一定的优化效果。

此外, 改进的 FasterRCNN 模型的归一化均方误差 *nMSE* 为 0.001 226, 相较于传统的 FasterRCNN 模型的归一化均方误差 *nMSE* 降低 40.31%。该指标表明了 FasterRCNN 模型经过改进后, 使得布氏硬度检测精度得到提升, 鲁棒性得以增强。

通过准确率 *Accuracy*, 归一化均方误差 *nMSE* 两个指标计算比较, 可以验证改进方案的有效性。同时, 各项指标都有所提升, 表明改进后的 FasterRCNN 模型对检测布氏硬度压痕具有更好的检测效果, 更高的检测精度。

本文展示部分布氏硬度压痕的检测效果, 其中原始的布氏硬度压痕图像如图 8 所示, 图 8 (a) 为表面未锈蚀, 表面情况差, 压痕边缘模糊的图片, 图 8 (b) 为表面锈蚀, 表面情况好, 反光效果好, 压痕边缘清晰的图片。基于 FasterRCNN 模型和改进的 FasterRCNN 模型的布氏硬度检测效果对比分别如图 9 (a)、(b) 所示。

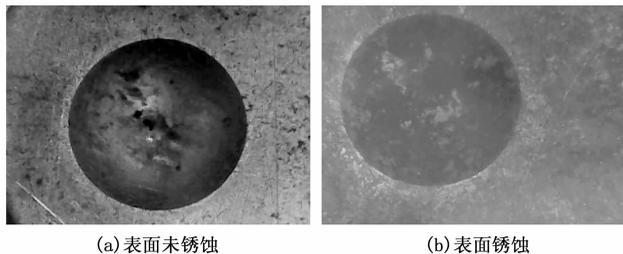


图 8 原始布氏硬度压痕图

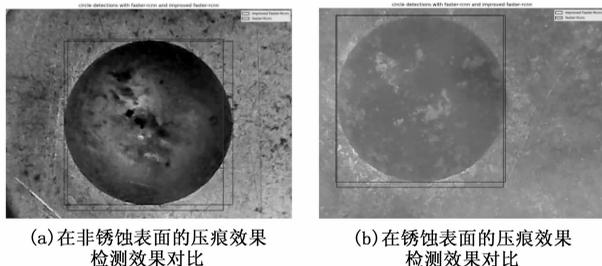


图 9 FasterRCNN 模型与改进 FasterRCNN 模型的压痕检测效果对比图

根据图 9 可知, FasterRCNN 网络对于检测锈蚀表面以及非锈蚀表面的布氏硬度压痕都具有很好的检测效果, 表明基于 FasterRCNN 网络模型的布氏硬度压痕检测方法适用于锈蚀和光滑金属表面工况。同时改进的 FasterRCNN 网络相较于传统的 FasterRCNN 网络, 布氏硬度压痕定位框更为准确, 推导得出的布氏硬度压痕直径更精准。

4 结束语

本文提出基于改进 FasterRCNN 模型的布氏硬度检测方法, 建立压痕圆数据集进行模型训练。通过检测效果证明, 该检测方法适用于锈蚀和光滑金属表面工况, 可以自动检测布氏硬度压痕。

同时, 本文针对传统的 FasterRCNN 模型的特点与不足, 结合布氏硬度检测的需求和特点, 对传统的 FasterRCNN 模型进行如下改进:

1) 结合布氏硬度检测的特点, 在 classification 网络中边框回归损失函数中加入预测检测框的长与宽的方差, 在改进的函数优化目标中加入预测检测框宽与高之间差距最小, 使得基于改进的 FasterRCNN 模型布氏硬度检测能够提供更加准确的目标预测检测框, 取得更精准检测效果。

2) 对自建的数据集进行数据增强, 在不易提取大量图片时, 有效扩充数据集数量, 使模型学到更多有效特征, 解决模型过拟合, 泛化能力差的缺点, 使得模型的鲁棒性增强, 同时提高模型在不同亮度下的判断能力。

通过对比改进的 FasterRCNN 模型与传统 FasterRCNN 模型的准确率 *Accuracy*, 归一化均方误差 *nMSE*, 发现改进后的各项指标均较改进前的指标有提升。其中, 准确率 *Accuracy* 从 96.35% 提升到 97.08%, 归一化均方误差 *nMSE* 从 0.002 054 降低到 0.001 226。证明了改进的 Fast-

erRCNN 模型对于检测布氏硬度压痕圆具有更好的检测效果, 更高的检测精度, 为布氏硬度检测提供了一种结合深度学习的、有效的测量解决方案。

参考文献:

- [1] 陈波, 李付国, 何敏. 延性金属材料损伤变量的实验表征方法研究 [J]. 稀有金属材料与工程, 2011, 40 (11): 2022-2025.
- [2] 郭东明, 孙玉文, 贾振元. 高性能精密制造方法及其研究进展 [J]. 机械工程学报, 2014, 50 (11): 119-134.
- [3] 邹声文, 郭少华, 付锦锋, 等. 球压试验压痕尺寸准确快速测量方法探究 [J]. 广东化工, 2019, 46 (3): 53-54.
- [4] 宋月, 白丽娟, 孙晓冉, 等. 布氏硬度测量方法浅析 [J]. 理化检验 (物理分册), 2020, 56 (11): 28-30.
- [5] 李和平. 根据压痕深度计算布氏硬度值的方法初探 [J]. 理化检验 (物理分册), 2019, 55 (4): 219-221.
- [6] 西北工业大学. 硬度块压痕直径测量方法及装置 [P]. 中国: CN201810242632.7, 2018-09-21.
- [7] 单忠德, 张飞, 任永新, 等. 基于机器视觉铸件布氏硬度在线检测技术研究 [J]. 机械工程报, 2017, 53 (1): 157-164.
- [8] 刁金凤, 陈涛, 任翔, 等. 基于机器视觉的布氏硬度机测量技术研究 [J]. 计量与测试技术, 2021, 48 (10): 33-35.
- [9] MICHAELKASS, ANDREW WITKIN, DEMETRI TERZOPOULOS. Snakes: active contour models [J]. International Journal of Computer Vision, 1988, 1 (4): 321-331.
- [10] 叶润, 张成, 李旭, 等. 基于计算机视觉的客机舱门门识别与定位技术研究 [J]. 计算机测量与控制, 2021, 29 (3): 224-229.
- [11] 胡丹丹, 张莉莎, 张忠婷. 基于改进 YOLOv3 和立体视觉的园区障碍物检测方法 [J]. 计算机测量与控制, 2021, 29 (9): 54-60.
- [12] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39 (6): 1137-1149.
- [13] 赵永强, 饶元, 董世鹏, 等. 深度学习目标检测方法综述 [J]. 中国图象图形学报, 2020, 25 (4): 629-654.
- [14] 王玉峰. 布氏硬度的误差分析 [J]. 天津冶金, 2016 (2): 59-60, 64.
- [15] 卫闻达, 张斌. 布氏硬度自动测量中多圆检测方法 [J]. 计算机与数字工程, 2021, 49 (3): 567-572.
- [16] 董健. 基于机器视觉的布氏硬度测量研究 [D]. 内蒙古: 内蒙古科技大学, 2012.
- [17] 中国机械工业联合会. 金属材料布氏硬度试验 第 3 部分: 标准硬度块的标定: DIN EN ISO 6506-3-2006 [S]. 2012-12-31.
- [18] 常城, 李天剑, 敖勤. 基于图像处理的布氏硬度测试系统设计 [J]. 实验技术与管理, 2010, 27 (6): 61-63.
- [19] 周飞. 布氏硬度测量误差分析 [J]. 计量与测试技术, 2011, 38 (3): 32.

(下转第 83 页)