

一种基于改进 Faster RCNN 的金属材料 工件表面缺陷检测与实现研究

代小红^{1a}, 陈华江², 朱超平^{1b}

(1.重庆工商大学 a.电子商务及供应链系统重庆市重点实验室 b.人工智能学院, 重庆 400067;
2.重庆科技学院 机械与动力工程学院, 重庆 401331)

摘要: 目的 针对传统检测算法在工件表面缺陷检测上的局限性, 以及检测精度不高、准确率较低、检测过程繁琐等问题, 提出了一种基于改进 RCNN 的金属材料工件表面缺陷检测算法。方法 图像预处理过程中, 运用了图像缺陷定位标注与图像数据的增强处理的方法。模型训练时为了避免某些分类数据不足, 防止因数据集过小导致系统测试模型出现过拟合现象, 使用了对原图像进行数据扩增处理。检测网络模型设计时, 采用非极大值抑制算法对缺陷图像进行候选区域筛选, 构建了区域建议网络, 实现网络多层特征的复用和融合, 在减少候选区域冗余的基础上提高系统的检测精度。引入多级 ROI 池化层结构设计算法, 消除 ROI 池化取整而产生的系统偏差, 实现高效并准确检测零件表面缺陷的目的。基于 ROI-Align 算法的原图位置坐标改进, 利用双线性插值法获得原图的位置坐标, 克服了基于最近邻插值法的 ROI-Pooling 设计算法带来的像素位置偏移和检测不匹配 (misalignment) 的问题。结果 设计的检测方法在测试集上, 金属材料工件表面目标缺陷检测速度达 22 帧/s, 准确率达 97.36%, 召回率达 95.62%。结论 与传统的工件表面检测方法相比, 改进的 FasterRCNN 方法对目标识别与定位处理具有较快的速度与较高的准确度, 能在复杂场景条件下, 提升工件表面缺陷的检测性能。

关键词: 金属材料工件; 表面缺陷识别; Faster RCNN; 深度学习; 目标检测

中图分类号: TH169; TP391.4 **文献标识码:** A **文章编号:** 1001-3660(2020)10-0362-10

DOI: 10.16490/j.cnki.issn.1001-3660.2020.10.043

Surface Defect Detection and Realization of Metal Workpiece Based on Improved Faster RCNN

DAI Xiao-hong^{1a}, CHEN Hua-jiang², ZHU Chao-ping^{1b}

(1.a.Chongqing Key Laboratory of E-commerce and Supply Chain System, b.School of Artificial Intelligence, Chongqing Technology and Business University Chongqing 400067, China; 2.School of Mechanical and Power Engineering, Chongqing University of Science and Technology, Chongqing 401331, China)

收稿日期: 2020-04-30; 修订日期: 2020-06-13

Received: 2020-04-30; Revised: 2020-06-13

基金项目: 教育部科技发展中心产学研创新基金项目 (2018A02049); 重庆市教育科学规划项目 (2018-GX-348)

Fund: Innovation Fund Project of Industry-University-Research Center of Science and Technology Development of the Ministry of Education (2018A02049), Chongqing Education Science Planning Program (2018-GX-348)

作者简介: 代小红 (1969—), 男, 硕士, 教授, 从事图像处理、模式识别和系统控制研究。

Biography: DAI Xiao-hong (1969—), Male, Master, Professor, Research focus: image processing, pattern recognition and system control.

通讯作者: 陈华江 (1969—), 男, 硕士, 副教授, 从事机械设计与制造研究。邮箱: 13594143410@163.com

Corresponding author: CHEN Hua-jiang (1969—), Male, Master, Associate professor, Research focus: mechanical design and manufacturing research. E-mail: 13594143410@163.com

引文格式: 代小红, 陈华江, 朱超平. 一种基于改进 Faster RCNN 的金属材料工件表面缺陷检测与实现研究[J]. 表面技术, 2020, 49(10): 362-371.

DAI Xiao-hong, CHEN Hua-jiang, ZHU Chao-ping. Surface defect detection and realization of metal workpiece based on improved faster RCNN [J]. Surface technology, 2020, 49(10): 362-371.

ABSTRACT: The work aims to propose a new algorithm in surface defect detection of metal workpiece based on an improved RCNN method in view of the limitation of traditional detection algorithm in the detection of workpiece surface defects, as well as the problems of low precision, low accuracy and tedious detection process. In the process of image pre-processing, the methods of image defect location and annotation and image data enhancement were used. While in model training, in order to avoid the shortage of some classification data and avoid the over fitting phenomenon of system test model caused by too small data set, the original image was processed through data amplification. In the design of detection network model, the non-maximum suppression algorithm was used to filter candidate regions of defect image so that a regional suggestion network was constructed, which realized the reuse and fusion of multi-layer network features and improved the detection precision of the system on the basis of reducing the redundancy of candidate. A multi-level ROI pool layer structure design algorithm was introduced to eliminate the system deviation caused by ROI pooling and rounding, which could effectively and accurately detect the surface defects of parts. The position coordinate of original drawing based on ROI-Align algorithm was improved and the position coordinate of original drawing was obtained by bilinear interpolation method, which overcame the problem of pixel position deviation and detection misalignment caused by ROI-Pooling design algorithm based on nearest neighbor interpolation method. The detection method proposed in this paper proved that in the test set, the detection speed of the target defects on the surface of metal workpiece was 22 fps, the accuracy rate was 97.36%, and the recall rate was 95.62%. Compared with the traditional workpiece surface detection method, the improved Faster RCNN method has faster speed and higher accuracy for target identification and positioning processing, which can improve the detection performance of workpiece surface defects under complex environment.

KEY WORDS: metal workpiece; surface defect identification; Faster RCNN; deep learning; target detection

金属材料工件是机械加工过程中一些产品的重要组成部分,金属材料工件质量的优劣直接影响着企业产品的市场竞争力,因此对机械加工过程中的金属材料工件表面缺陷进行检测就显得非常重要。金属材料工件制造工艺简单,但结构复杂,检测技术要求高,传统的检测方法主要有渗透检测技术、涡流检测技术、磁粉检测技术、目视检测技术和图像检测技术^[1],这些检测技术主要存在以下几个方面的问题:一是检测速度慢,导致检测效率低;二是检测过程中产生环境污染;三是检测过程繁琐,不能实现自动化检测与识别。如何提高金属材料工件表面缺陷的检测,是当今工业生产过程中值得深入研究的问题。本文研究的金属材料工件主要限于汽车零件的生产与加工过程产生的表面缺陷。

通过查询现有的文献资料,基于金属材料工件表面检测的研究成果不多,文献[2]的研究中提出了基于深度卷积神经网络的 SAR 自动目标跟踪与检测算法,方法中采用一类优化的 DNNs 网络结构对 SAR 图像目标进行分类训练。文献[3]提出了深度学习及其在铸造工件缺陷自动检测中的应用与研究。文献[4]研究了基于改进的 Faster RCNN 的齿轮外观缺陷识别方法,针对传统缺陷识别算法泛化差和人工提取特征耗时,提出了一种改进的、较快的、基于区域卷积神经网络(Faster RCNN)的齿轮缺陷识别模型。文献[5]提出利用机器视觉对轮毂工件铸造面的缺陷区域定位,提取缺陷特征,从而进行特征缺陷识别。在这些方法中,首先对金属材料工件表面的图像进行离线采

集,然后对图像继续进行加强处理,最后进行表面缺陷识别,很难适应流水线自动化生产要求。杨薇等^[6]对车辆在线实时检测时,提出了基于 Faster RCNN 的改进算法,其改进方法主要体现在以下几个方面:一是改进 RPN 的设计方案;二是 Anchor 数量的增加;三是为了提高系统处理的实时性和准确率,在模型训练时加入多尺度策略方案。此改进方案的优点是计算速度相对更快,缺点是对小目标的检测效果不好。

鉴于上述分析,传统的运动物体实时检测与金属材料工件缺陷检测算法存在以下共性问题:一是检测效率低;二是检测过程繁琐;三是检测识别系统对小目标不敏感;四是多目标检测时会产生漏检现象。通过项目组查询国内外相关文献,目前没有有效的检测方法以及分类识别算法能同时解决上述问题。

Joseph Redmon 等^[7]提出了 YOLO 算法模型,此模型可以直接学习图像的全局信息,且可以进行端到端训练,缺点是 YOLO 对成堆目标的检测准确率较低。在此借鉴了 YOLO 算法模型设计思想,在提高系统准确率的同时,能够实现流水线自动化检测与分类识别,解决了传统检测方法在小目标和多目标检测存在的错检与漏检等问题。

对于金属工件表面缺陷检测,提出了利用深度学习技术,从生产线上采集工件图像,再从图像中提取缺陷信息,通过学习金属工件表面缺陷特征,建立金属材料工件缺陷的网络检测与缺陷识别模型。这种改进的 RCNN 网络模型用于金属材料工件表面缺陷的定位和检测,从而提高了系统的缺陷识别效率,有利

于工业生产中产品质量的提高。

1 材料与方法

1.1 实验环境

实验硬件由计算机、图像采集设备、测距仪和步进电机等构成。计算机配置为：主频为 4.2 GHz Intel Core i7 7700K CPU 处理器，16 G 内存。图像采集设备的工业相机是维视 MV-EM200C 型（小型 GigE 千兆网带帧寸工业相机），焦距为 16 mm，分辨率的像素大小为 1600×1200，帧率为 60 帧/s。测距仪为博世激光 GLM50，仪器精度为±1.5 mm，测量范围为 0.05~50 m。软件系统包括：OpenCV 视觉库、Pytorch 深度学习框架和 Ubuntu18.0 操作系统。

1.2 图像采集

本文构建了如图 1 所示的图像采集与预处理系统，系统构成包括：检测平台，待检测样品，影像投影透镜，光学照明系统，光电耦合传感器 CCD 摄像机，图像处理系统，缺陷图像的目标区域成像系统。系统工作时，将具有缺陷的金属材料工件放置在检测平台上，在光电耦合传感器 CCD 的作用下形成了工件的原始图像，再将此图像输入图像处理系统，最后获取了工件图像的缺陷区域部分。图像采集时需要对待测工件进行两次成像，当金属材料工件进入检测阶段时，图像采集系统先对金属材料工件正面进行采集，然后再对金属材料工件的反表面进行采集。

由于要训练深度学习网络，前期需要采集大量图像，从采集的图像中识别出金属材料工件表面有缺陷的图像，这个图像的采集周期较长。图像采集系统如图 1 所示。




图 1 金属材料工件表面缺陷检测系统

Fig.1 Surface defect detection system of metal workpiece

1.3 检测原理与方法

金属型材料工件在生产过程中，由于各种因素致使工件表面产生裂纹、污绩、麻点和缺口等表面缺陷，这些具有缺陷的零件在工业生产中称为瑕疵工件。表面缺陷检测是机器视觉技术在工业领域的应用，是智能制造的关键环节。金属材料工件的缺陷主要表现为

以下几种形式：崩角、划痕、斑点、凹坑和色差等^[9-10]。

检测系统的机电传动与光学成像原理为：在机电传动系统的作用下，待测金属工件通过传送带进入光学成像系统，来自于 LED 光源发出的照明条纹，经过成像镜头（成像镜头主要由反射镜、透镜和投影镜头构成）投射到投影屏上，此投影屏是透射式投影屏。投影屏上的光路投射至待测金属工件的物体表面，同时载物台的机电驱动系统完成平台自转，有利于系统获得待测金属工件的全部表面图像，而表面图像的高亮区域信息，通过光电耦合传感器器件形成了待测金属工件的原始目标图像。检测系统根据获得的目标图像，在相应算法的支持下进行处理（图像分割、降噪和滤波等），从而实现了对待测金属工件表面缺陷的特征提取与检测处理。由于有时候缺陷部位相对于金属材料工件面积来说相对较小，因此检测过程分为缺陷定位和缺陷分类。

2 图像预处理

2.1 图像缺陷定位与标注

通过对输入图像的预处理，实现了图像缺陷的定位与图像缺陷的分类计数。系统进行缺陷检测时，其图像缺陷体现在灰度差值上，每一灰度差值是待检测图像的灰度值与标准图像的灰度值之差。而彩色图像的处理是将其输入到一个色域空间中（此色域空间与设备无关），经系统处理转换到 CIELAB 色彩空间，此时图像缺陷也就体现在待检图像与标准图像形成的差值上^[11]，系统进行判别时，根据获得的图像差值与系统阈值相比较，判断是否在其设定的参数范围内，就能获得待测工件带有缺陷的二值图像，其算法过程如图 2 所示。

判别过程与方法为：在此将待测图像表示为 $k_{\text{原}}$ ，标准图像库的图像表示为 $k_{\text{标}}$ ，检测系统处理时的图像差表示为 $p=|k_{\text{标}}-k_{\text{原}}|$ ，而图像差值 p 包含了图像的色差信息（三基色分量 R 、 G 、 B 的值），将所获得的图像差值 p 进行阈值化处理（ T_1 为系统检测时设定的初始化阈值）。若图像色差大于 T_1 ，系统就会自动对缺陷像素计数；当统计计数值大于系统参数预设定的阈值时，表示此待测工件的图像属于缺陷图像^[12]。

上述判别方法对于缺陷明显或缺陷较大的工件容易识别，而当系统检测微小工件缺陷时，效果明显较差。如检测凹陷类、崩角类和杂质类缺陷时系统表现较好，而检测碰伤类和划伤类缺陷时表现欠佳。为了解决微小缺陷带来的问题，使用以下方法进行处理：由于三基色分量 R 、 G 、 B 的色差属于单通道色彩信息，其他两个通道的信息不够突出，此时阈值化 T_1 处理后，需要对缺陷图像的相邻像素继续进行比较识别处理，当色差值大于设定阈值时，微小的缺陷就会突出显示，从而对工件进行缺陷图像标注。




图 2 图像预处理与缺陷分类

Fig.2 Image preprocessing and defect classification

2.2 图像数据的增强处理

数据增强有利于图像缺陷识别的后续处理,数据增强过程中是将系统中得到的有限量数据加工产生出比原数据量大的等价图像数据,再将这些等价图像数据作为系统的神经网络参数进行训练^[8,14]。数据增强的方式主要有以下几种形式:平移处理、噪声处理、图像裁剪、图像缩放、图像旋转以及图像翻转。噪声处理是在图像处理过程中,由于深度卷积神经网络训练的数据量太大,会导致训练过程中产生过拟合的情况,这种过拟合的现象将会使网络训练中得不到图像的特征数据,为此需要在处理过程中加随机噪声的方式进行处理,以达到图像数据增强的目的。图像旋转是按顺时针方向或者逆时针方向对图像以一定角度转动而产生新图像的过程。图像翻转不是将图像在水平方向上转动 180°,而是对图像进行镜面对称方式的转动过程^[15-16]。对原始图像进行自适应直方图均衡化增强,也是图像数据增强的常用处理方法。

2.3 图像模糊性消除处理

在生产线上对运动的金属材料工件表面进行图像采集时,采集到的图像很可能存在模糊现象,在对图像识别之前,需要先对图像进行消除模糊处理,把模糊图像变为清晰图像,提高金属材料工件表面缺陷的识别率^[17]。在图 2 的图像预处理过程中,在此利用拉普拉斯算子 (Laplace Operator) 可以锐化图像边缘的特性。处理过程中,首先将待处理图像转为灰度图像,利用拉普拉斯算子实现一次卷积运算,此时生成了系统的计算图;其次再通过计算图得到该图的方差,方差大小表示此计算图的灰度值变化情况;最后利用计算图的方差阈值来判断图像的清晰度,值越小,图像越模糊,值越大,图像越清晰。本文根据计算图的方差来确定图像是属于清晰图像还是模糊图像^[18]。通过统计大量的图像系统的阈值,选取 $T=20$, T 为清晰图像与模糊图像的计算图方差的阈值。实际应用中,若 $T \geq 20$,则原图属于清晰图像;若 $T < 20$,则原图属于模糊图像。

在识别出模糊图像之后,本文基于生成式对抗网络设计去模糊算法来消除图像的运动模糊。在条件生成式对抗网络选用深度卷积神经网络,以适应对金属材料工件表面图像数据的处理,并重新设计图像内容损失函数,用于模型的训练,并实现输入的模糊图像与网络输出的清晰图像之间的图像共享内容不发生

改变,保证内容的真实性,从而消除图像的模糊性^[19-20]。

3 基于改进 Faster RCNN 网络结构与算法设计

Faster RCNN 网络架构模型是建立在 RCNN 和 FastRCNN 的基础之上,将 FastRCNN 网络模型与区域建议网络模型 (RPN) 融合,通过共享卷积层来训练全连接层,形成一个完整的金属工件缺陷网络检测系统,如图 3 所示。区域建议网络模型 (RPN) 将取代选择性搜索 (Selective Search) 进行建议区域的识别与提取。为了提高系统的识别效率和得到具有高精度和高可靠性的特征建议区域,区域建议网络模型 (RPN) 直接利用全网络的卷积特征识别金属工件缺陷图像的建议区域。因此,FastRCNN 网络模型与区域建议网络模型 (RPN) 的整合提高了系统的检测速度,同时也提高了系统的检测准确度。Faster RCNN 创造性地提出了利用卷积神经网络 (CNN) 生成区域的候选框,区域建议网络与缺陷检测网络共享卷积层,RPN 处理时采取自动学习的方式;当系统对候选框进行计算时,将较少地占用系统资源与时间开销,给缺陷检测识别网络的计算带来微不足道的时间消耗^[21-22]。Faster RCNN 网络与 RCNN 网络和 FastRCNN 网络相比,Faster RCNN 网络对目标识别与定位处理具有较快的速度与较高的准确度。

3.1 基于 ROI-Align 算法的原图位置坐标改进

Faster RCNN 在得到一系列大小各异的候选框区域,同时要对候选框区域进行精确分类及其位置坐标判断^[23]。在系统处理之前,这些大小各异的候选框区域需要归一化处理,形成相同大小的候选框区域,才能输入下一层的卷积神经网络。而 Faster RCNN 是通过 ROI-Pooling 的操作来实现归一化处理的,即获取特征图像大小不同的兴趣区域 (ROI),利用 ROI-Pooling 池化,形成一些具有同样大小的 Feature map。ROI-Pooling 池化能够快速提高候选框的处理速度,ROI-Pooling 的处理过程如下:首先,根据输入图像将 ROI 映射到特征图所在的位置;其次,系统根据映射形成网格,这些网格具有相同的大小;最后,对网格进行池化处理。实现了将不同大小的候选框处理成具有相同大小对应的特征图,这些特征图大小与 ROI 和特征提取网络的输出图间存在弱关联性。

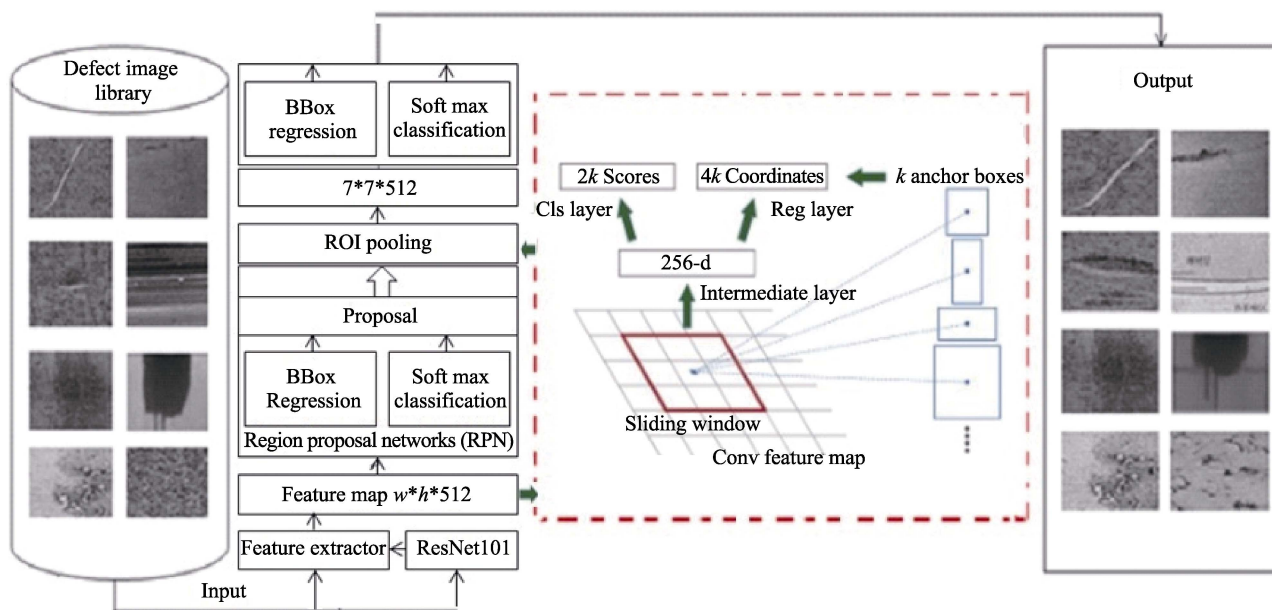


图3 Faster RCNN 网络模型结构
Fig.3 Faster RCNN network model structure

从以上处理过程中发现,输入图像经映射到特征图位置时,虽然得到了同样大小的网格,但是原图上的 ROI 坐标是一个浮点数,而 ROI-Pooling 是通过最近邻插值法获取原图的位置坐标,此位置坐标是整数像素,特征提取网络是 16 倍下采样处理,原图通过最近邻插值法产生了大小不等的像素位置偏移,导致系统处理时形成了偏差,偏差将会影响系统的检测或分割的准确度,导致检测不匹配 (misalignment) 问题的产生^[24]。当目标区域较大时,这一误差的影响可以容忍,但是对于一些较小的目标区域时,这一误差是系统不能允许的。针对这一问题,在此通过 ROI-Align 算法进行缺陷检测与识别方法的改进,其方法是在 ROI 区域与原图像映射过程中,利用双线性插值法获得原图的位置坐标,而非前述的最近邻插值法。通过实验验证,采用 ROI-Align 算法较大地提升了系统的处理性能。

3.2 改进的 ROI 池化层算法设计

单级的 ROI 网络是用一张表保存模型的编号,在传统单级 ROI 网络算法的基础上,引入了空间金字塔思想设计多级 ROI 池化层,即将单级池化转变为重叠池化。为了降低池化层输出时的特征维度,系统首先对池化层输出进行扩充,形成具有多级的较小特征;其次,对形成的多级较小的特征采用稀疏编码方式,实现多级特征融合处理,这样就降低了检测系统池化层输出的特征维度^[25]。传统的单级池化策略与重叠池化策略相比,前者获得的是系统输出的单一大小特征映射,而重叠池化策略在处理时体现出了对目标形变具有较好的鲁棒性,本文运用多级金字塔的池化策略设计,能够提高系统处理时的深度网络性能。系统设计时池化层采用的是最大池化采样方法,这样可以降低由于邻域大小受限带来的估计值方差^[26]。由

于索引表只保存了特征图的索引信息,其内容单一有限,目前大规模图像处理只需要 2 层的索引表,当场景规模扩大时,将索引扩大到 3 层或更多层,但是 ROI 索引有其自身的开销与复杂维度,建议在场景规模较小时,尽量采用低层次的索引表进行处理。

从系统内存资源开销上进行实验测试,测试机器内存为 16 G,用若干模型进行两类输入测试,一类是基于模型数量较少的情形 (A 类),在此选取模型数为 100、200、500;另一类是基于模型数量较多的情形 (B 类),在此选取模型数为 1000、2000、3000、4000、5000;在 Faster RCNN 网络检测系统中,分别采用 0 层 ROI 算法设计、单层 ROI 算法设计和 2 层 ROI 算法设计等三种方案进行对比实验,通过实验分析模型输入与 ROI 池化层的内存资源占用情况,以选择合适的网络优化方案,满足系统的检测需要。测试结果如表 1 所示,表 1 中显示为不同模型数量输入时,系统处理所占用的资源开销,即模型输入后处理时的占用内存与总内存之比。

表 1 模型训练与 ROI 池化层的内存占用对比分析
Tab.1 Comparative analysis of memory usage between model training and ROI pooling layer

Model category	Model number (each)	Memory resource occupation of ROI pooling layers at all levels/%		
		0 layer	1 layer	2 layer
Class A	100	0.863	0.925	0.950
	200	1.600	1.663	1.613
	500	3.813	1.938	1.950
Class B	1000	7.938	1.969	1.969
	2000	15.475	2.013	1.969
	3000	22.563	2.044	1.969
	4000	—	2.094	1.981
	5000	—	2.144	1.981

由表 1 的模型训练结果可知,当 Faster RCNN 网络检测系统不采用 ROI 算法设计时,模型数量较少的 A 类训练可以勉强应对检测系统的需要,随着模型数量的递增,检测系统内存开销呈几何级数增加,直到最后,当模型数量为 4000 和 5000 时,系统无法识别。当 Faster RCNN 网络检测系统采用 ROI 算法设计时,当系统训练输入较小的 A 类模型时,单层 ROI 算法设计的检测系统,可以有效地降低系统内存占用,满足系统检测需求,同时节约了多层 ROI 结构设计的成本与开销;当系统训练输入较大的 B 类模型时,随着模型数量输入的增加,多级 ROI 算法设计比单级 ROI 算法少占用系统的内存资源,提高了系统的检测效率。

3.3 卷积神经网络特征提取模块

图像缺陷的特征提取是本文的重点研究内容之一,此环节是在图像模糊性处理后进行的。在此利用卷积神经网络进行图像的特征提取,从实验过程来看,发现卷积层数越多,越能提取图像中较多的复杂特征,并且卷积神经网络模型具有较强的拟合能力。但是,卷积层数越多,给系统带来了另外的问题:一是数量较多的卷积层使系统变得更加复杂,从而产生了模型需要大量的运算,形成了庞大的计算量问题;二是过于复杂的网络卷积层,将会形成过拟合现象。本文结合特征提取的实际情况,在多次模型训练的基础上,结合网络性能、卷积层数(模型深度)、系统效率等因素,设计了具有 3 个模块的卷积神经网络模型。

在卷积神经网络模型的前置模块设计中,为了解决由于系统单一的卷积核尺寸带来的特征提取不完整问题,在模型设计时同一卷积模块采取了差异化的卷积核设计方法,如本文的 5*5 和 7*7,这种方法利用了图像的空间特征,实现了系统的差异化提取特征,后续过程加入了卷积核 1*1*Z 中,利用 Z 的调节实现了信道维度的降低,从而克服了由于卷积层数越多带来的复杂计算问题,提升了系统的特征提取效率^[13,27]。在中置模块中,为了增强系统的稳定性,运用了非规则交叉卷积核设计思想,如本文的 1*5 和 5*1,这一方法是了解决系统多尺度特征的提取(如不规则缺陷图像),从而使模型能够适应不同尺度特征的训练;中置模块的设计增强了系统模型的非线性表达能力,从而提高了非线性拟合能力,这种卷积结合也有利于缺陷特征的提取。

3.4 分类损失函数与位置回归损失函数

系统处理时,为了获取每一个滑动窗口 k 个区域建议,每个锚点(anchor)以当前的滑动窗口为中心,并取相应的尺度和一定的长宽比。在此选择 4 种尺度和 4 种长宽比,每一个滑动窗口将会产生 $k=16$ 个锚点。对于 1 个 $W \times H$ 的特征图,将会产生 $k \times W \times H$ 个区域建议。位置回归层(L_{reg})用于回归区域建议产生

边界框,由于每个滑动窗口(sliding window)产生 k 个区域建议,因此位置回归层(L_{reg})有 $4k$ 个平移缩放参数输出并进行编码。分类层(L_{cls})的作用是对区域建议是否为前景或背景进行打分,区域建议为前景或者背景的概率在此分类层(L_{cls})有 $2k$ 个得分估计。区域建议网络(RPN)训练时,检测系统遵循 Fast RCNN 中的多任务损失函数 f_{loss} :

$$\begin{aligned} (\{P_i\}, \{t_i\}) = & \frac{1}{N_{\text{cls}}} \sum_i f_{\text{cls}}(p_i, p_i^*) + \\ & \lambda^* \frac{1}{N_{\text{reg}}} \sum_i p_i^* f_{\text{reg}}(t_i, t_i^*) \end{aligned} \quad (1)$$

式中: i 为系统中第 i 个候选区域锚点(anchor)的索引号; p_i 是锚点(anchor _{i})的目标预测概率即候选区域的分类概率; p_i^* 为候选区域标签(1 表示正样本,0 表示负样本); t_i 是一个向量; t_i^* 表示预测包围盒(k 锚点包围盒)的是候选区域对应的 GT 坐标向量; λ 是 N_{cls} 与 N_{reg} 的平衡权重,实验过程取 $\lambda=10$; N_{cls} 为分类层损失函数的归一化系数; N_{reg} 为位置回归层损失函数的归一化系数; f_{cls} 、 f_{reg} 分别是分类损失函数(目标类与非目标类)和位置回归损失函数,其函数定义分别如下:

$$f_{\text{cls}}(p_i, p_i^*) = -\lg[p_i p_i^i + (1-p_i)(1-p_i^*)] \quad (2)$$

$$f_{\text{reg}}(t_i, t_i^*) = \sum_{i \in (w, h, x, y)} f_{\text{smooth}(L1)}(t_i + t_i^*) \quad (3)$$

式(2)中,区域的中心点坐标用 $O(x, y)$ 表示,区域的宽度和高度分别用 w 、 h 表示, $f_{\text{smooth}(L1)}(x)$ 为鲁棒的损失函数,其表示为:

$$f_{\text{smooth}(L1)}(x) = \begin{cases} x^2 / 2 & \text{abs}(x) < 1 \\ \text{abs}(x) - 1/2 & \text{其他} \end{cases} \quad (4)$$

本文定义图像候选框有许多互相重叠的区域(Intersection over Union, IoU),候选区域与实际目标区域(ground truth)的交集并集之比为 f_{IoU} 。当 $f_{\text{IoU}} > 0.7$ 、 $p_i^* = 1$ 时,候选区域为前景;当 $f_{\text{IoU}} < 0.3$ 、 $p_i^* = 0$ 时,候选区域为背景。实验中为了减少候选区域冗余现象,在此采用非极大值抑制算法对候选区域进行筛选,将 $f_{\text{IoU}} > 0.7$ 的区域全部进行合并,从而实现了在不影响系统检测结果的情况下大幅度减少候选区域数量。

在此为系统参数预设了 4 种尺度与 4 种长宽比,4 种尺度参数分别为 64^2 、 128^2 、 256^2 、 512^2 ,4 种长宽比分别为 1:1、1:2、1.5:1、2:1。因此,在每一个位置处就会生成 16 个锚点,系统的区域建议网络将会精确地提取区域候选框,并对提取的区域候选框运用非极大值抑制算法筛选,根据需要获得具有较高得分的区域候选框。

4 实验结果与分析

4.1 数据集的建立

从图 1 中获取的原始图像,建立磕碰伤、车刀痕、

杂质 3 种零件表面缺陷样本数据集,并对数据集图像中的缺陷进行标注识别。试验样本取于重庆 XXX 车辆配件公司,样本集中包含缺陷金属工件 1120 个,采集了 2240 幅图像,为了提高处理效率,将原始图像压缩为固定分辨率(480×640)的样本图像。在此采取 2.2 节的图像数据增强处理方法进行数据集扩充,以实现金属工件表面缺陷特征的提取和提高系统的模型泛化能力。数据增强处理后,数据集的图像数量将会扩充到 20 160 幅。采用文献[28-29]方法进行数据集格式处理,即将图像标注成 PASCAL VOC 的标准文件格式。从增强处理后的数据集 20 160 幅图像中随机抽取 15 200 幅图像作为训练集,3800 幅图像作为验证集(训练集与验证集之比设置为 4:1),其余 1160 幅图像作为测试集,要求处理过程中训练集、验证集和测试集互相之间无重叠现象。为了提高系统的缺陷识别能力和减少不必要的原始数据,在此采取 2.3 节图像模糊性消除方法进行图像处理。

4.2 数据集的训练过程

对于 Softmax 逻辑回归分类器,损失函数采用交

叉熵,数据集的训练过程中采取了批量随机梯度下降法进行训练。本文分别取数据训练集 15 200 幅图像、数据验证集 3800 幅图像、数据测试集 1160 幅图像作为输入的样本数据,针对常见的图像缺陷检测网络模型(如 RCNN、Fast RCNN、Faster RCNN)和本文基于 Faster RCNN 改进型网络进行对比测试,测试结果如表 2 所示。表 2 中, $f_{\text{precision}}$ 是系统工件缺陷检测的准确率, r_{recall} 为召回率; F_{measure} 是取决于准确率($f_{\text{precision}}$)和召回率(r_{recall})的函数,其取值大小是两者平衡的结果,即:

$$F_{\text{measure}} = 2 * f_{\text{precision}} * r_{\text{recall}} / (f_{\text{precision}} + r_{\text{recall}}) \quad (5)$$

从表 2 的测试结果可以看出,本文研究中针对传统检测方法的改进主要体现在以下几个方面:一是对基础网络结构进行优化选择;二是在 ROI-Pooling 算法的基础上,引入了 ROI-Align 算法设计;三是改变传统单层 ROI 网络算法为多层 ROI 网络算法。因此,基于 Faster RCNN 改进型网络对于复杂环境下的金属工件表面缺陷检测具有检测速度快、检测精度高和 mAP 值高等优势,能够满足当前工件缺陷表面的识别与检测。

表 2 不同训练集测试对比分析

Tab.2 Comparative analysis of tests in different training sets

Number of trials	Model algorithm	Precision/% ($f_{\text{precision}}$)	Recall/% (r_{recall})	F_{measure}	1 picture detection time/s	Detection speed/fps
1	R-CNN	85.47	84.80	0.851	0.054	19
2	Fast R-CNN	90.72	89.63	0.902	0.041	24
3	Faster R-CNN	93.79	92.38	0.931	0.036	28
4	The improved method of this paper	97.36	95.62	0.965	0.046	22

模型训练中将上述三类样本数据测试集输入网络,初始化系统的高斯分布选取方差为 10^{-3} ,标准正态分布的均值为 0。设定系统的最大训练步数为 8000,初始学习率为 10^{-3} ,率衰减因子为 0.87,系统批处理时的规格大小设为 24,通过实验得到了系统检测的损失函数 f_{loss} 曲线图,如图 4 所示。从图 4




图 4 损失函数 f_{loss} 曲线图
Fig.4 Floss curve of loss function

可以看出,模型训练的第 1 个 1500 内,损失函数 f_{loss} 表现出了较快的收敛速度,其下降幅度明显快于后面的训练过程,损失函数 f_{loss} 的值太大没有实际意义。实验训练中从 1500 次迭代开始记录,从 1500~6500 的训练迭代步数来看,收敛过程呈小幅下降趋势;当训练迭代步数为 6500~8000 时,训练集的损失函数 f_{loss} 表现趋于平缓,训练模型收敛,当模型运行的训练迭代步数为 8000 时,系统停止运算。

4.3 缺陷误检与多目标检测

图 5a 是本文方法检测的误检样本数据,经过实验分析发现此 2 个误检在于系统成像时,光源的照射角度,通过改变待测工件的位置参数,即可解决此问题。将目标的边缘误判成了目标缺陷,产生了检测系统的边缘效应。若不改变参数设置,由于本文改进检测系统对误判有较高的容忍性,将完好工件形成误检的机率很小,对整体检测的影响几乎可以忽略。而将图 5a 经过传统 Faster RCNN 网络检测后,同样也识别为 2 个缺陷,检测结果如图 5b 所示,再进行相关系统参数调整,误检始终无法消除,说明传统 Faster

RCNN 对边缘误判的容忍性差。

为了验证本文检测系统对目标检测的识别能力，人为在一个金属工件表面不同位置预设了 2 个杂质缺陷、1 个划痕缺陷、1 个凹坑缺陷和 1 个碰伤缺陷。将此工件加入测试集进行检测，通过实验发现，本文方法能够准确检测出这 5 个缺陷，证明了本文方法的

多目标检测可靠，各类缺陷检测的效果较好，检测结果如图 5c 所示；将同样金属工件经过传统 Faster RCNN 检测后，只检测出了 2 个杂质缺陷和 1 个凹坑缺陷，说明传统 Faster RCNN 方法对多目标检测准确率低，这也体现了对传统 Faster RCNN 方法改进的必要性。




图 5 目标边缘误检与多目标检测对比

Fig.5 Comparison of target edge error detection and multi-target detection

4.4 实例检测与应用

实验中在各种复杂自然环境条件下对改进 Faster RCNN 网络进行了测试，测试集的数据包含了多类型缺陷的金属工件，图 6a、b、c、d 的左图均为工件图像，图 6a 右图均为工件检测后的碰伤缺陷图像，图 6b 右图均为工件凹坑缺陷图像，凹坑缺陷的直径为 $40\ \mu\text{m}$ ，图 6c 右图均为工件划伤缺陷图像，图 6d 右图均为工件杂质缺陷图像，杂质缺陷的直径为 $20\ \mu\text{m}$ 。测试表明：改

进 Faster RCNN 网络检测系统具有较高的准确率，检测识别效果明显高于传统检测系统。但是，在试验过程中发现，本文方法对细微的划伤工件缺陷存在定位错位的现象，如图 6c 所示，导致整体的平均检测精度降低，通过对待测工件的检查发现，由于划伤工件的样本太少，占总样本的比例太低，导致了训练模型的敏感度不够，经过增加此类工件样本数，扩充样本的训练集，提高了本文改进方法检测的平均检测精度。




图 6 本文改进方法的检测应用

Fig.6 Detection application of the improved method in this paper

5 结论

本文分析了基于 Faster RCNN 网络的目标检测方法,在 ResNet101 结构的基础上,引入多级 ROI 池化层结构设计算法,消除了 ROI 池化取整而产生的系统偏差,利用双线性插值法获得原图的位置坐标,克服了基于最近邻插值法的 ROI-Pooling 设计算法带来的像素位置偏移和检测不匹配等问题。检测网络模型构建与系统设计中,采用非极大值抑制算法对缺陷图像进行候选区域筛选,构建了区域建议网络,引入了 FPN 多尺度融合特征网络,实现网络多层特征的复用和融合,在减少候选区域冗余的基础上,提高了系统的检测精度与速度。在此只与传统 Faster RCNN 检测网络相比较,各项指标优于传统 Faster RCNN 的检测方法,改进 RCNN 方法的缺陷检测速度达 26 fps,准确率为 97.36%,召回率为 95.62%。

通过项目组研究测试表明:改进的 Faster RCNN 检测能够自动学习待测金属工件的表面特征,可以满足金属工件生产与加工处理中的缺陷提取要求;对于工件图像中缺陷区域与正常图像的像素区域存在较小的像素值差时,本文模型表现出比传统 Faster RCNN 检测算法更优秀的识别能力。该模型能够对各类金属工件表面缺陷进行有效检测,特别是对于传统检测方法无法辨别的金属工件表面缺陷,本文改进检测方法具有较好的检测效果,完全能够满足日常工业企业的检测需要,从而提高企业产品的优良率。

参考文献:

- [1] 答建成,周细应,周涛,等. 汽车零部件表面强化技术研究现状及展望[J]. 表面技术, 2015, 44(7): 68-75.
DA Jian-cheng, ZHOU Xi-ying, ZHOU Tao, et al. Research status and prospects of surface strengthening technology of auto parts[J]. Surface technology, 2015, 44(7): 68-75.
- [2] 李松,魏中浩,张冰尘,等. 深度卷积神经网络在迁移学习模式下的 SAR 目标识别[J]. 中国科学院大学学报, 2018, 35(1): 75-83.
LI Song, WEI Zhong-hao, ZHANG Bing-chen, et al. Target recognition using the transfer learning-based deep convolutional neural networks for sar images[J]. Journal of University of Chinese Academy of Sciences, 2018, 35(1): 75-83.
- [3] YAN W X. Research on deep learning and its application on the casting defects automatic detection[D]. Guangzhou: South China University of Technology, 2016.
- [4] 吉卫喜,杜猛,彭威,等. 基于改进的 Faster R-CNN 的齿轮外观缺陷识别研究[J]. 系统仿真学报, 2019, 31(11): 2198-2204.
JI Wei-xi, DU Meng, PENG Wei, et al. Research on gear appearance defect recognition based on improved faster r-cnn[J]. Journal of system simulation, 2019, 31(11): 2198-2204.
- [5] 王一妍. 基于机器视觉的轮毂铸造面质量检测研究[D]. 沈阳: 沈阳工业大学, 2019.
WANG Yi-yan. Research on quality inspection of wheel casting surface based on machine vision[D]. Shenyang: Shenyang University of Technology, 2019.
- [6] 杨薇,王洪元,张继,等. 一种基于 Faster R-CNN 的车辆实时检测改进算法[J]. 南京大学学报(自然科学), 2019, 55(2): 232-237.
YANG Wei, WANG Hong-yuan, ZHANG Ji, et al. An improved vehicle real-time detection algorithm based on faster-rcnn[J]. Journal of Nanjing University (natural science), 2019, 55(2): 232-237.
- [7] REDMON J, DIVVALA S, GIRSHICK R B, et al. You only look once: Unified, real-time object detection[J]. IEEE, 2016, 58: 779-788.
- [8] 薛月菊,朱勋沐,郑婵,等. 基于改进 Faster R-CNN 识别深度视频图像哺乳母猪姿态[J]. 农业工程学报, 2018, 34(9): 189-196.
XUE Yue-ju, ZHU Xun-mu, ZHENG Chan, et al. Lactating sow postures recognition from depth image of videos based on improved faster R-CNN[J]. Transactions of the Chinese Society of Agricultural Engineering, 2018, 34(9): 189-196.
- [9] XIANG X Z, NING L, GUO X L, et al. Engineering vehicles detection based on modified faster rcnn for power grid surveil-lance[J]. Sensors, 2018, 18(7): 2258.
- [10] DING W, TAYLOR G. Automatic moth detection from trap images for pest management[J]. Computers & electronics in agriculture, 2016, 123(C): 17-28.
- [11] 黄小玉,李光林,马驰,等. 基于改进判别区域特征融合算法的近色背景绿色桃子识别[J]. 农业工程学报, 2018, 34(23): 142-148.
HUANG Xiao-yu, LI Guang-lin, MA Chi, et al. Green peach recognition based on improved discriminative regional feature integration algorithm in similar background[J]. Transactions of the CSAE, 2018, 34(23): 142-148.
- [12] 周琼宇,谢蔚,王小芬,等. 基于人工神经网络预测 Ni-W 合金镀层的硬度和耐腐蚀性能[J]. 表面技术, 2016, 45(12): 140-146.
ZHOU Qiong-yu, XIE Wei, WANG Xiao-fen, et al. Artificial neural network-based prediction of hardness and corrosion resistance of Ni-W alloy coating[J]. Surface technology, 2016, 45(12): 140-146.
- [13] EVERINGHAM M, VAN G L, WILLIAMS C K, et al. The pascal visual object classes (voc) challenge[J]. International journal of computer vision, 2010, 88(2): 303-338.
- [14] HOU Q, CHENG M, HU X, et al. Deeply supervised salient object detection with short connections[J]. IEEE,

- 2019, 41(4): 815-828.
- [15] 赵德安, 吴任迪, 刘晓洋, 等. 基于 YOLO 深度卷积神经网络的复杂背景下机器人采摘苹果定位[J]. 农业工程学报, 2019, 35(3): 164-173.
- ZHAO De-an, WU Ren-di, LIU Xiao-yang, et al. Apple positioning based on YOLO deep convolutional neural network for picking robot in complex background[J]. Transactions of the Chinese Society of Agricultural Engineering (transactions of the CSAE), 2019, 35(3): 164-173.
- [16] 吴宇雳, 李渊强. 基于卷积神经网络的病理细胞核分割[J]. 重庆工商大学学报(自然科学版), 2019, 36(3): 67-71.
- WU Yu-li, LI Yuan-qiang. Convolutional network based pathological nucleus segmentation[J]. Journal of Chongqing Technology and Business University (natural science edition), 2019, 36(3): 67-71.
- [17] 冯小雨, 梅卫, 胡大帅. 基于改进 Faster RCNN 的空中目标检测[J]. 光学学报, 2018, 38(6): 0615004.
- FENG Xiao-yu, MEI Wei, HU Da-shuai. Aerial target detection based on improved faster r-cnn[J]. Acta optica sinica, 2018, 38(6): 0615004.
- [18] 林丽君, 殷鹰, 李雪琴, 等. 基于轮廓波包变换的磁瓦表面缺陷提取[J]. 应用基础与工程科学学报, 2016(2): 402-417.
- LIN Li-jun, YIN Ying, LI Xue-qin, et al. Defect extraction on magnetic tile surface based on contourlet packet transform[J]. Journal of basic science and engineering, 2016(2): 402-417.
- [19] 王佳盛, 陈燕, 曾泽钦, 等. 基于全卷积神经网络的荔枝表皮缺陷提取[J]. 华南农业大学学报, 2018, 39(6): 104-110.
- WANG Jia-sheng, CHEN Yan, ZENG Ze-qin, et al. Extraction of litchi fruit pericarp defect based on a fully convolutional neural network[J]. Journal of South China Agricultural University, 2018, 39(6): 104-110.
- [20] 刘畅, 张剑, 林建平. 基于神经网络的磁瓦表面缺陷检测识别[J]. 表面技术, 2019, 48(8): 330-339.
- LIU Chang, ZHANG Jian, LIN Jian-ping. Detection and identification of surface defects of magnetic tile based on neural network[J]. Surface technology, 2019, 48(8): 330-339.
- [21] 代小红. 模糊模式的手写数字识别技术研究 with 实现[J]. 重庆大学学报(自然科学版), 2011, 34(6): 117-122.
- DAI Xiao-hong. Research into handwritten numeral recognition technique based on fuzzy mode and its realization [J]. Journal of Chongqing University (natural science edition), 2011, 34(6): 117-122.
- [22] 王雪丽, 李昕. 基于相关滤波和卷积神经网络的目标跟踪算法[J]. 重庆工商大学学报(自然科学版), 2020, 37(1): 19-24.
- WANG Xue-li, LI Xin. Target tracking algorithm based on correlated filters and convolutional neural network[J]. Journal of Chongqing Technology and Business University (natural science edition), 2020, 37(1): 19-24.
- [23] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [24] ANTHIMOPOULOS M, CHRISTODOULIDIS S, EBNER L, et al. Lung pattern classification for interstitial lung diseases using a deep convolutional neural network[J]. IEEE transactions on medical imaging, 2016, 35(5): 1207-1216.
- [25] CHANG H T, GOU J N, LI X M. Application of faster image defect detection of industrial CT[J]. Journal of image and graphics, 2018, 23(7): 1061-1071.
- [26] 叶长文, 康睿, 戚超, 等. 基于 Faster-RCNN 的肉鸡击晕状态检测方法[J]. 农业机械学报, 2019, 50(12): 255-259.
- YE Chang-wen, KANG Rui, QI Chao, et al. Stunning state recognition method of broiler chickens based on faster region convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(12): 255-259.
- [27] LIU Y, CHENG M M, HU X, et al. Richer convolutional features for edge detection[C]//Computer vision and pattern recognition. Florida: IEEE, 2017: 5872-5881.
- [28] EVERINGHAM M, EALAMI S, VAN GOOL L, et al. The pascal visual object classes challenge: Aretrospective[J]. International journal of computer vision, 2015, 111(1): 98-136.
- [29] 郑喜贵, 龚胜, 尹韶辉, 等. 磁控微粉砂轮固化工艺对砂轮磨削性能的影响[J]. 表面技术, 2017, 46(10): 76-81.
- ZHENG Xi-gui, GONG Sheng, YIN Shao-hui, et al. Effects of curing process for magnetic control micro powder grinding wheel on grinding performance[J]. Surface technology, 2017, 46(10): 76-81.