

DOI:10.16136/j.joel.2022.01.0322

基于膨胀卷积的多尺度焊缝缺陷检测算法

谷 静*, 吴怡宁, 孟鑫昊

(西安邮电大学 电子工程学院, 陕西 西安 710121)

摘要:本文针对焊缝缺陷尺度变化不一导致的检测率效果不理想,提出了一种基于更快地区域卷积神经网络(faster region-based convolutional neural network, Faster R-CNN)对焊缝缺陷检测的改进算法。算法利用膨胀卷积在不同扩张率下进行特征融合,结合不同感受野下的卷积核更全面地提取不同尺度的特征信息,来提升目标的检测精度。同时利用深度可分离卷积,来对模型进行压缩,提高检测速度。实验表明,改进后的网络在保证运行速度的同时,能够提高检测速度,检测精度可以达到 72%。

关键词:焊缝缺陷检测; 更快地区域卷积神经网络(faster region-based convolutional neural network, Faster R-CNN); 特征融合; 膨胀卷积

中图分类号: TP391 **文献标识码:** A **文章编号:** 1005-0086(2022)01-0061-06

Weld defect detection based on expansion convolution multi-scale fusion

GU Jing*, WU Yining, MENG Xinhao

(School of Electronic Engineering, Xi'an University of Posts & Telecommunications, Xi'an 710121, China)

Abstract: This article in view of the different scale changes lead to the detection rate of weld defect effect is not ideal, is proposed based on a faster region-based convolutional neural network (Faster R-CNN) of weld defect detection algorithm of improved algorithm using convolution expansion characteristics under the different expansion rate, combination of convolution kernels under different receptive field more comprehensive to extract the feature information of different scales, to improve the target detection accuracy at the same time, the deep separable convolution is used to compress the model to improve the detection speed. The experiment shows that the improved network can improve the detection speed while ensuring the operation speed and the detection accuracy can reach 72%.

Key words: weld defect detection; faster region-based convolutional neural network (Faster R-CNN); feature fusion; expansion convolution

1 引 言

近年来,随着深度学习的发展,基于深度学习进行焊缝缺陷检测^[1]的相关研究已经取得了一定的成效。深度卷积神经网络模型 AlexNet^[2]的出现,让卷积神经网络(convolutional neural network, CNN)^[3]在图像识别与计算机视觉领域得到了很大的突破,涌现了许多像区域卷积神经网络(region-based convolutional neural network, R-

CNN)、YOLO(you only look once)、单点多盒探测器(single shot multibox detector, SSD)等经典的目标检测算法^[4]。和人工设计的特征比起来,卷积神经网络提取特征鲁棒性更好,语义信息更丰富,已在目标检测各领域取得了巨大成果。文献[5]提出了一种基于多分类支持向量机(multi-classification support vector machine, MSVM)的焊缝缺陷自动检测和分类技术,该方法涉及 3 个模块。在第一个模块中,使用改进的各向异性扩散

* E-mail: guj@xupt.edu.cn

收稿日期: 2021-06-14 修订日期: 2021-08-17

基金项目: 陕西省重点研发计划(2020SF-370)资助项目

方法对图像进行平滑。在第二个模块中,使用改进的大津法执行分割过程。最后,提取感兴趣区域的特征,并将其作为具有核高斯径向基函数的多类支持向量机的输入。文献[6]提出了一种基于多尺度特征金字塔的目标检测算法,通过对不同层次的特征进行尺度变化后,再进行信息融合,从而可以提取到比较底层的信息,但没有充分利用特征图的位置信息。文献[7]提出基于更快地区域卷积神经网络(faster region-based convolutional neural network, Faster R-CNN)^[8]模型的改进,通过改变滑动窗口的大小,并调整主干网络来提高小尺寸目标的检测精度。但是相对缺陷尺度跨度较大的目标及未融合和未焊透这些不易分辨的缺陷检测的精度都有待提高。

本文针对这个问题提出了一种基于膨胀卷积的多尺度焊缝缺陷检测算法。该算法的模型基于Faster R-CNN将不同感受野下的特征图进行融合,以增强特征的表现能力,学习不同尺度下的特征,以免造成信息丢失,并加入深度可分离卷积模

块对网络模型进行压缩,提高检测速度。

2 基于Faster R-CNN算法的改进

Faster R-CNN主要由Fast R-CNN^[9]和区域生成网络(region proposal network, RPN)^[10]两大部分组成,Faster R-CNN检测流程图如图1所示。图片经过主干网络来提取特征,然后用区域生成建议框RPN生成一系列候选框。Fast R-CNN对候选框区域内的目标分类,同时修正候选框的大小和位置,形成较精确的目标候选框。感兴趣的区域池化(region of interest pooling, ROI pooling)收集候选框,并计算出候选框的特征图。最后将特征图进行全连接层后经过Softmax分类器和边框回归,分别得到边框对应的类别和边框的偏移量,得到更准确的目标框。

Faster R-CNN虽然在检测精度上有很大的突破,但由于一些焊缝缺陷过小或尺度变化大导致其对于目标缺陷的特征表达能力仍存在不足。因此本文提出了一种基于膨胀卷积的多尺度焊缝缺陷检测算法。




图1 Faster R-CNN检测流程图

Fig. 1 Faster R-CNN detection flow chart

2.1 多支路膨胀卷积特征融合

卷积核的大小决定了对图像局部加权的范围,即感受野的大小。感受野是原始输入图像上每层卷积神经网络输出特征图的像素映射区域的大小,不同的感受野对不同尺度的目标检测有不同的影响。Faster R-CNN算法中主干网络的卷积核大小固定,只能使用固定大小的感受野对图片进行特征提取,并不能有效的提取不同尺度下的特征信息。在焊缝缺陷中,焊缝缺陷大小不一,只对同一感受野下的缺陷进行特征提取,很可能会导致其他过大或者过小的目标在深层网络中严重丢失,造成焊缝缺陷的误检和漏检等问题。因此,将膨胀卷积引入Faster R-CNN算法中,来增大卷积核的感受野,通过调整膨胀

率和卷积核的参数来找到适合自己数据集的感受野。

2.1.1 膨胀卷积

膨胀卷积(dilated convolutions)^[11]的主要思想是在不增加参数量的前提下增大卷积核的感受野,让每个卷积输出都包含较大范围的信息,同时可以保证输出特征映射大小不变。相比传统卷积,膨胀卷积增加了用来表示扩张之后卷积核大小的扩张率。传统卷积表达式为:

$$I(x, y) \times K(x, y) = \sum_{s=0}^m \sum_{t=0}^n K(s, t) I(x-s, y-t), \quad (1)$$

式中, $I(x, y)$ 表示卷积前的图像在点 (x, y) 上的值,

$K(s, t)$ 表示大小为 $m \times n$ 的卷积核。

膨胀卷积的表达式为:

$$I(x, y) \cdot \times K(x, y) = \sum_{s=0}^m \sum_{t=0}^n K(s, t) I(x - ls, y - lt), \quad (2)$$

式中, $\cdot \times$ 代表膨胀卷积运算, l 代表扩张因子。

2.1.2 基于膨胀卷积的多支路特征融合

不同尺度物体的检测性能与感受野呈正相关。较大的感受野对大目标检测效果更好,较小的感受野对小目标检测效果更好。为了对每层的特征图信息进行更加全面的提取,设计了多支路膨胀卷积特征融合(mult-branch dilated feature fusion, MDFF),其卷积块如图2所示,分别采用不同大小卷积核和不同的膨胀率相互作用,得到4个不同感受野的卷积核下的特征图进行像素融合(add)^[12],融合成卷积块来代替原来的卷积层。




图2 MDFF卷积块

Fig. 2 MDFF convolution block

像素融合使图像特征下信息量增加,但图像的维度本身没有变化,只增加了每一维度下的信息量。另一种比较常见的DenseNet^[13]中的特征融合(concat)是通道数的合并,描述了图像本身特征数(通道数)的增加,而每一特征下的信息量没有变化。

$$D_{\text{add}} = \sum_{i=1}^c (X_i + Y_i) * K_i, \quad (3)$$

$$D_{\text{concat}} = \sum_{i=1}^c X_i * K_i + \sum_{i=1}^c Y_i * K_{i+c}. \quad (4)$$

从式(3)和(4)可以看出,concat为横向或纵向空间上的叠加,而add为简单的像素叠加。add等价于concat之后对应通道共享同一个卷积核,所以add具有更少的参数量和计算量,而concat在通道上进行融合可以实现特征重用。因此在实验部分对add

和concat进行比较,结果显示add特征融合的效果好,故本实验对不同感受野下的特征图进行add融合。

在Faster R-CNN算法中,主干网络通常采取VGG16^[14]来提取特征。视觉几何组(visual geometry group, VGG16)的网络结构简洁,使用多个较小卷积核(3×3)的卷积层代替一个较大的卷积层。一方面能减少参数量,一方面相当于进行了更多的非线性映射,能增加网络的拟合能力。本文将VGG16中的conv2_2、conv3_2、conv4_2、conv5_2卷积层全部替换为MDFF模块,在改进后的主干网络中提取不同尺度下的信息,得到MDFF-VGG16网络,如图3所示。




图3 MDFF-VGG16网络

Fig. 3 MDFF-VGG16 network

2.2 深度可分离卷积

在主干网络中增加MDFF模块,增加了参数量。网络参数的增加必定会导致计算量的增加,使网络的检测速度下降。因此引入深度可分离卷积模块来保证检测精度的前提下提高检测速度。

深度可分离卷积(depthwise separable convolu-

tion, DSC)^[15]是将一个常规卷积拆分为逐通道卷积(depthwise convolution, DC)和逐点卷积(pointwise convolution, PC)两个过程,深度可分离卷积如图4所示。若输入图片尺寸为 $D_F \times D_F$ 、 N 通道,设常规卷积核尺寸为 $D_K \times D_K$ 、 M 通道,则输出图片尺寸为 $D_F \times D_F$ 、 N 通道。DSC由常规卷积拆分成了DC和PC两个部分,DC负责滤波,卷积核尺寸为 $D_K \times D_K$ 、 M 通道。PC负责转换通道,卷积核尺寸为 1×1 、

N 通道。深度可分离卷积和常规卷积得到的特征图相同,但在计算量上,参数量减少的比例式为:

$$P = \frac{D_K \times D_K \times M \times D_F \times D_F + M \times N \times D_F \times D_F}{D_K \times D_K \times M \times N \times D_F \times D_F} = \frac{1}{N} + \frac{1}{D_K^2} \quad (5)$$

可见,当卷积核尺寸为 3×3 时,其计算量比常规卷积减少了8到9倍。因此,把卷积层换成深度可分离卷积,来提高检测的速度。




图4 深度可分离卷积

Fig. 4 Depth separable convolution

3 实验结果分析

3.1 评价标准

评判目标检测系统有3个重要的指标: IOU 、 mAP 和检测速度。

IOU 的全称为交并比(intersection over union),是目标检测中使用的一个概念, IOU 计算的是“预测的边框”和“真实的边框”的交叠率,即交集和并集的比值。 IOU 表达式如式(6)。

$$IOU = \frac{A \cap B}{A \cup B} \quad (6)$$

平均精度(average precision, AP)表示算法是通过训练得到的模型在检测某一类别上的表现程度,均值平均精度(mean average precision, mAP)表示算法是模型在检测所有目标类别的平均表现程度, AP 和 mAP 如式(7)、式(8)所示, mAP 的值越大,焊缝缺陷检测模型越好。

$$AP = \int_0^1 P(r) dr, \quad (7)$$

$$mAP = \frac{\sum AP}{N} \quad (8)$$

3.2 仿真与数据分析

本文实验使用的焊缝图像数据集为合作项目中自建数据集,包括2340张图片,按照8:2的比例分为训练集和测试集。数据集中包含4类缺陷,分别为裂纹(crack)、气孔(pore)、未焊透(lof)和未熔合(lop),人工标注后,将图片转化为VOC2007数据集格式,用图片进行训练。为了更好地验证本文方法对焊缝缺陷检测结果的影响,采用不同的实验策略进行仿真验证。首先探究了MDFF模块不同融合方式对检测结果的影响。分别是以VGG16作为主干网络的Faster R-CNN原始模型、对MDFF-VGG16进行concat融合的Faster R-CNN模型和对MDFF-VGG16进行add融合的Faster R-CNN模型等3种模型进行对比,不同融合方式的实验对比见表1。

由表1可知,add融合方式在 mAP 结果上相比concat融合方式和原始模型,分别提高了21%和12%,可见通道间的特征重用并不能很好地学习焊缝的特征信息,相反会使部分特征信息弱化。再相比Faster R-CNN原始模型,add的融合方式提高了每一类缺陷的检测精度,尤其对裂纹、未焊透、未熔合这三类检测精度较低的缺陷,和原始模型数据相

比,分别提高了 11%、14%、21%。充分证明改进模型进行 add 融合对于不易分辨目标和难检测目标的优越性。

表 1 不同融合方式的实验对比
Tab.1 Experimental comparison of different fusion methods

Feature fusion	Crack	Lop	Lof	Pore	<i>mAP</i>
None	0.565 5	0.576 1	0.531 9	0.726 2	0.600 2
Concat	0.429 8	0.482 4	0.473 6	0.655 8	0.510 4
Add	0.678 6	0.719 6	0.740 5	0.766 2	0.726 2

图 5 为数据集中随机选取的几张焊缝图片的改进前后仿真结果对比,可以看出改进后的模型对原始网络中某些误框和误检的缺陷能进行很好的纠正。

考虑到模型参数量的增加带来检测速度的下降,继续对 MDFF-VGG16 中的普通卷积用深度可分离卷积代替,在不降低检测精度的前提下减小计

算量。表 2 为加入深度可分离卷积和原始 Faster R-CNN 模型测试时间的对比。

表 2 不同模型测试时间的对比
Tab.2 Comparison of test time of different models

Model	Proposals	Speed/(img/s)
Faster R-CNN	300	1.00
Faster R-CNN+MDFF	300	1.43
Faster R-CNN+MDFF+DSC	300	1.20

图 6 将 SSD、YOLOv3 和现有文献中改进的多特征 Faster R-CNN 模型(Faster R-CNN+MF)与本文模型的 *AP* 对比。可以看出针对本数据集下的焊缝缺陷检测,两阶段的检测算法比一阶段的检测效果更好。同一数据集下本文模型与 Faster R-CNN+MF 模型相比,*mAP* 提高了 5%,进一步验证了本文算法的有效性。




图 5 改进前后仿真结果对比:(a)(c) 改进前仿真结果;(b)(d) 改进后仿真结果

Fig.5 Comparison of simulation results before and after improvement:(a)(c) Simulation results before improvement;(b)(d) Simulation results after improvement




图 6 不同算法的 *AP* 比较

Fig.6 *AP* comparison of different algorithms

4 结 论

由于传统 Faster R-CNN 算法在进行缺陷检测中对缺陷特征提取不够充分,因此将膨胀卷积与 Faster R-CNN 相结合,提出了一种改进的 Faster R-CNN 焊缝缺陷检测算法。实验结果表明,本文提出

的方法不仅提高了难检测缺陷和不易分辨的缺陷检测精度,还提取了更多的边缘、细节等特征信息,在焊缝缺陷检测方面具有更好、更广泛的应用前景。但由于缺陷检测速度相对较慢,在未来的研究中,仍要进一步提高模型的检测速度。

参考文献:

[1] WANG J R, WANG G T, YANG B, et al. A review of the application of deep learning in weld defect detection[J]. Mechanical and Electrical Engineering Technology, 2021, 50(3): 65-68.
王靖然, 王桂棠, 杨波, 等. 深度学习在焊缝缺陷检测的应用研究综述[J]. 机电工程技术, 2021, 50(3): 65-68.
[2] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.

- [3] SCHMIDHUBER, Jürgen. Deep learning in neural networks: an overview[J]. *Neural Networks*, 2015, 61: 85-117.
- [4] CHEN K Q, ZHU Z L, DENG X M, et al. A review of deep learning for multi-scale target detection[J]. *Journal of Software*, 2021, 32(4): 1201-1227.
陈科圻, 朱志亮, 邓小明, 等. 多尺度目标检测的深度学习研究综述[J]. *软件学报*, 2021, 32(4): 1201-1227.
- [5] MALARVEL M, SINGH H. An autonomous technique for weld defects detection and classification using multi-class support vector machine in X-radiography image[J]. *Optik-International Journal for Light and Electron Optics*, 2021, 231(10): 166342.
- [6] LIN T, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017: 936-944.
- [7] QU H F. Research and implementation of automatic inspection of weld defects based on deep learning[D]. Beijing: Beijing University of Posts and Telecommunications, 2019: 1-96.
渠慧帆. 基于深度学习的焊缝缺陷自动检测研究与实现[D]. 北京: 北京邮电大学, 2019: 1-96.
- [8] 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.
- [9] GIRSHICK R. Fast R-CNN[C]//IEEE International Conference on Computer Vision, February 7-13, 2015, Santiago, Chile. New York: IEEE, 2015: 1440-1448.
- [10] XU G J, ZHANG Y, LAI X Y. Faster R-CNN deep network for tea bud image recognition[J]. *Journal of Optoelectronics · Laser*, 2020, 31(11): 1131-1139.
- 许高建, 张蕴, 赖小焱. 基于 Faster R-CNN 深度网络的茶叶嫩芽图像识别方法[J]. *光电子·激光*, 2020, 31(11): 1131-1139.
- [11] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions [EB/OL]. (2016-04-30) [2021-06-14]. <https://arxiv.org/abs/1511.07122>.
- [12] JI X S, LI J M. An improved method for character detection of Fasters-RCNN circuit board[J]. *Journal of Small and Microcomputer Systems*, 2020, 41(6): 1291-1295.
吉训生, 李建明. 一种改进的 Faster-RCNN 电路板字符检测方法[J]. *小型微型计算机系统*, 2020, 41(6): 1291-1295.
- [13] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]//IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017: 2261-2269.
- [14] CHENG S H, SHANG G C, ZHANG L. Handwritten digit recognition based on improved VGG16 network[C]//The Tenth International Conference on Graphics and Image Processing (ICGIP 2018), December 12-14, 2018, Chengdu, China. Washington: SPIE, 2018.
- [15] HOWARD A, SANDLER M, CHEN B, et al. Searching for MobileNetV3[C]//IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Korea (South). New York: IEEE, 2019: 1314-1324.

作者简介:

谷 静 (1975—), 女, 硕士, 副教授, 硕士生导师, 主要从事通信与信息系统、图像处理方面的研究。