

# 基于轮廓变形的工业产品表面划痕检测算法

袁 梦 苏工兵 曾文豪

武汉纺织大学机械工程及自动化学院,湖北 武汉 430200

**摘要:**针对工业产品表面划痕实例分割精度低、耗费运算量大的问题,提出了一种基于轮廓变形的产品表面划痕的实例分割算法。该算法通过目标检测和轮廓变形两阶段的任务来实现对划痕的精确分割。在自建的划痕实例分割数据集上进行了对比实验,结果表明,实例分割算法对于工业产品表面划痕分割的各种 AP 值分别达到 41.2%、67.7%和 43.9%,均高于主流的逐像素分割模型,为工业产品表面划痕的精细检测领域提供了一种新的研究思路。

**关键词:**深度学习;实例分割;缺陷检测;轮廓变形

**中图分类号:**TP391.4

**DOI:** 10.3969/j.issn.2097-065X.2024.05.037

## 0 引言

工业产品表面划痕不仅影响产品的外观,还容易导致产品的性能下降和安全隐患,因此及早发现并准确识别表面划痕对于工业生产过程的质量控制至关重要。

对于图像的实例分割领域,许多研究者已经意识到基于轮廓的分割方法相比于传统的逐像素分割方法拥有更少的参数量和更高的处理速度等一系列优点。

近年来,随着深度学习方法在目标识别领域的应用急速发展,众多深度学习方向的研究者提出以深度学习为重点的轮廓分割方法。比如 Polygon-RNN<sup>[1]</sup>、Curve-GCN<sup>[2]</sup>、ContourNet<sup>[3]</sup>等方法实现了对目标轮廓的端到端学习和优化。Deep Snake<sup>[4]</sup>方法则是利用深度神经网络来学习特征表示,并结合传统的轮廓演化过程,实现对目标实例的准确分割。

本研究运用基于轮廓变形的实例分割方法对工业产品表面划痕进行实例分割,这种高效、精细的分割能力对于工业产品表面划痕的质检具有关键意义。

## 1 算法结构

本研究算法包括两个部分:划痕目标检测部分和划痕轮廓变形部分。目标检测部分用来生成划痕的矩形检测框。划痕轮廓变形部分用于生成划痕的精准外形轮廓。两个部分共用一个特征提取骨干网络,特征提取骨干网络运用经典的 DLA-34<sup>[5]</sup>网络。

在目标检测部分运用 CenterNet 检测器<sup>[6]</sup>。

划痕轮廓变形部分包含轮廓初始化和轮廓精细变形的 2 个阶段的分任务,具体来说,轮廓初始化大约分为以下 3 个步骤:

(1)在目标检测阶段所得到的矩形框的四边分别提取中点,形成一个菱形目标框,4 个点作为划痕目标极点的初始点。

(2)因为初始点与划痕轮廓的极点存在着较大的偏差,所以对 4 个初始点进行进一步的变形,将初始点的特征输入轮廓变形网络中,输出 4 个极点的偏移量,最终通过偏移量将初始极点迁移到上、下、左、右 4 个方向的极点上。

(3)在上一步所获取的 4 个极点顺着目标检测框的方向分别引出一条直线段,线段的长度一般选取目标框各个边长的 1/4,若线段长度超过检测框,则删除多余部分,将所有线段进行首尾相连形成一个初始轮廓,轮廓为八边形。轮廓定为八边形可以更好地表达目标的形状和位置,能够去除大量不必要的像素点,在很大程度上能够修正目标定位的偏差。

在轮廓精细变形阶段,以上述八边形为初始轮廓,在八边形上将最顶部的极点作为开始的点,在八边形上每隔相同的距离就进行一次点的采样,连续采样 128 次,就能将初始轮廓构造为一个具有循环结构的有序点集合,每个节点的度都为 2 且首尾相连。将获取到的每个节点的特征通过轮廓变形网络能够得到其对应坐标的偏移量,最后,将这 128 个点的坐标加上其偏移量就是进行了一次轮廓的变形,相同的操作进行 3 次,最终就能得到目标的精确轮廓。由预测框得到目标轮廓的具体过程如图 1 所示。

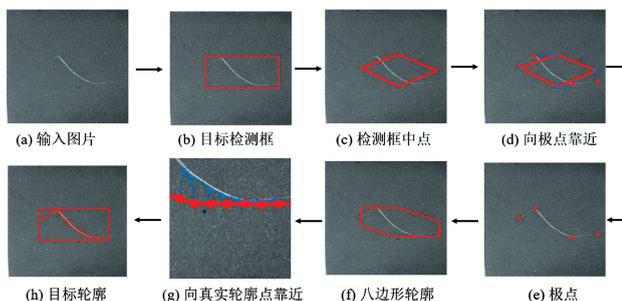


图 1 轮廓变形过程

**基金项目:**湖北省科技专项(2019AEE011);湖北省数字化纺织装备重点实验室开放基金(KDTL2022011);国家自然科学基金(51375351)

## 2 轮廓变形网络结构

轮廓变形网络结构沿用 Deep Snake 基本网络架构。轮廓变形网络的主体由主干网络、融合模块和预测模块 3 个部分组成。输入的特征由特征提取骨干网络提取到的特征和该点位置坐标 2 个部分拼接而成,将这些特征经过以上 3 个部分的处理,能够输出相应顶点坐标的偏移数值,并经过重复几次的迭代操作得到最终的预测结果。主干网络由 8 个循环卷积(CirConvBn-ReLU)层组成,每个循环卷积层都使用残差网络连接方式。主干网络的主要作用是对轮廓上采样的各个顶点的特征进行学习更新,同时实现了上下文传播推理的过程。融合模块将主干网络每一层的输出特征和经过所有主干网络层的最终特征进行级联,然后将其依次通过一个  $1 \times 1$  卷积层和一个最大池化层,融合模块的主要作用是全面融合特征提取网络所有层次的特征信息。预测模块由 3 个  $1 \times 1$  的卷积层组成,最终得到每个顶点的偏移量。轮廓变形网络具体结构如图 2 所示。

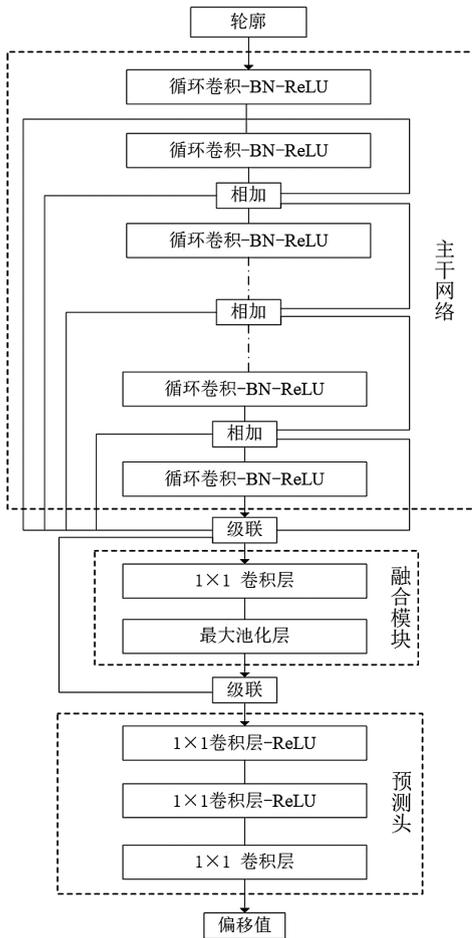


图 2 轮廓变形网络结构

由于轮廓上每个顶点的度都等于 2 且首尾相连,轮廓便可视为一个循环图结构,因此可以将特征扩展为周期信号,使用循环卷积来获取轮廓特征。

将初始轮廓上的有序点组成集合  $P = \{x_i\}_{i=1}^N$ , 其中,第  $i$  个点的坐标表示为  $(x_i, y_i)$ ,  $N$  为点的个数。对于循环卷积的输入特征,每个顶点都要进行以下操作,例如顶点  $x_i$ , 其输入特征是特征提取骨干网络的输出特征和顶点坐标的连接,表示为  $f_i = [F(x_i); x'_i]$ , 其中  $F(x_i)$  为特征提取骨干网络的特征映射,在输出特征图的顶点坐标处使用双线性插值计算能够得到。附加的顶点坐标为  $x'_i$ , 用于表示轮廓顶点在空间上的编码关系,由于坐标应具有平移不变性,因此  $x'_i = (x_i - x_{\min}, y_i - y_{\min})$ 。循环卷积的输出特征与输入特征长度相同,对于一个周期信号  $(f_N)_i \triangleq f_{i \bmod N}$ , 其循环卷积的映射运算为:

$$(f_N * k)_i = \sum_{j=-r}^r (f_N)_{i+j} k_j \quad (1)$$

式中,  $k$  是一个可学习的核函数;  $r$  是卷积核的大小; 符号  $*$  为卷积运算。

循环卷积的计算方式与标准卷积类似,但是它能够更好地编码周期信号的特征,并且能够捕捉相邻顶点之间的关系。在所有的实验中,循环卷积的核大小固定为 9。

## 3 实验对比和分析

### 3.1 数据集

本研究通过专业相机实际拍摄获取工业产品表面包含复杂划痕的 590 张图像,采取旋转、翻转、调节亮度和仿射变换这 4 种增强方式得到 1 180 张图像,使用 8:2 的比例随机抽取 944 幅图像作为训练数据集、236 幅作为验证数据集。并对所有图像使用 Labelme 标注工具进行划痕轮廓的多边形标注,最后组建成实验所需格式的数据集。

### 3.2 实验配置与评价标准

#### 3.2.1 实验配置

实验采用的硬件配置为 Intel Core i9-10900 @2.80 GHz 处理器,显卡为 NVIDIA GeForce RTX 3070Ti 8GB。软件环境为 CUDA11.6 和 cuDNN8.3.2,操作系统为 Ubuntu18.04。网络模型基于 Pytorch 框架搭建,python 版本为 3.8,pytorch 版本为 1.12.1。

本研究参考 deep snake 的参数设置,根据实验设备的硬件条件以及数据集的具体特点,将 batch size 设置为 4,将 epoch 设置为 200,使用 Adam 优化器,初始学习率设为  $1e^{-4}$ , 分别在第 80 个和第 120 个周期衰减为原来的一半,所有实验中均使用多尺度数据增强策略。

#### 3.2.2 评价指标

本研究实验使用实例分割算法中最常用的评估

指标平均精度 (Average Precision, AP) 作为模型精确度的评价指标。计算公式如下:

$$AP = \frac{1}{N_{gt}} \sum_{i=1}^{N_{gt}} P_i \quad (2)$$

式中,  $N_{gt}$  为样本个数。

平均精度使用掩码交并比 (Intersection Over Union, IoU) 进行评估。IoU 的计算公式如下:

$$IoU = \frac{mask_{pre} \cap mask_{gt}}{mask_{pre} \cup mask_{gt}} \quad (3)$$

$AP_{50}$  是指只统计预测目标掩码与真实值掩码的  $IoU > 0.5$  的实例的平均精度。 $AP_{75}$  是指只统计预测目标掩码与真实值掩码的  $IoU > 0.75$  的实例的平均精度。 $AP(0.50:0.95)$  意味着  $IoU$  在  $0.5 \sim 0.95$  的范围内被认为是检测到, 表示在不同  $IoU$  阈值 (从  $0.50 \sim 0.95$ , 步长为  $0.05$ ) 上的平均  $mAP$ 。

### 3.3 实验对比与分析

表 1 所示为本研究算法在数据集上与经典实例分割模型的对比实验结果。根据第三组实验结果与前两组的实验结果对比可得, 本研究算法针对产品表面划痕的特点对检测网络进行了非常正向的优化, 检测精度对比现有的逐像素分割算法模型有了非常大的提升。

表 1 与经典实例分割算法对比实验表 %

算法	$AP(0.5:0.95)$	$AP_{50}$	$AP_{75}$
Mask R-CNN	34.7	62.3	36.5
PANet	38.9	65.9	41.1
Ours	41.2	67.7	43.9

将本研究算法和主流检测算法进行定性对比实验在数据集中的部分结果如图 3 所示。

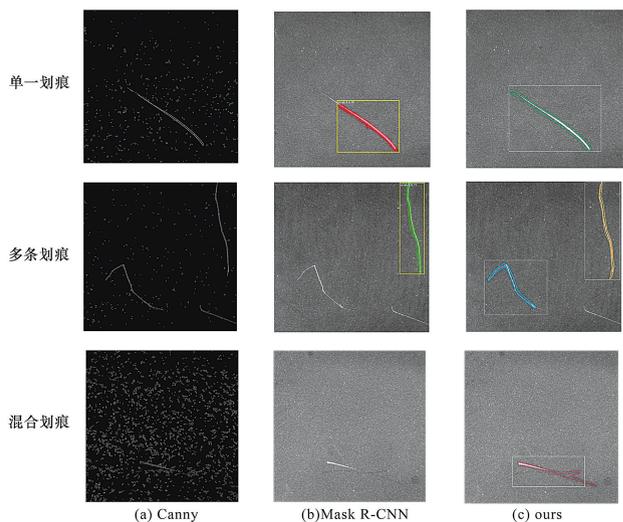


图 3 多算法定性对比实验结果

从图 3 可以看出, 本研究算法能够较为准确的分割出复杂划痕的具体轮廓, 除了能够对不同方向的划痕进行准确定位和分割外, 对多条合在一起的划痕也能够进行较高精度的轮廓分割, 同时能够修正目标检测阶段边界框的错误定位。对于其他算法, Canny 边缘检测的划痕识别的效果很差, 许多划痕无法识别出来, 还会误检许多边缘。Mask R-CNN 算法的定位和分割任务都非常不准确, 且存在漏检的情况。因此, 本研究算法是一种有效的产品表面复杂划痕检测算法。

### 4 结语

针对工业产品表面划痕实例分割精度低、耗费运算量大的问题, 提出了一种基于轮廓变形的产品表面划痕的实例分割算法, 该算法通过目标检测和轮廓变形两阶段的任务来实现对划痕的精确分割。与以往的深度学习分割模型相比, 优势如下: 计算量远远小于逐像素分割方法, 使得实例分割的速度更快、效率更高; 修正目标检测算法预测结果的偏差, 该算法能通过目标检测后续的轮廓变形阶段在目标检测有偏差的基础上仍能准确分割划痕轮廓。

#### 参考文献:

- [1] Castrejon L, Kundu K, Urtasun R, et al. Annotating object instances with a polygon-RNN[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 5230-5238.
- [2] Ling H, Gao J, Kar A, et al. Fast interactive object annotation with curve-GCN[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 5257-5266.
- [3] Wang Y, Xie H, Zha Z, et al. ContourNet: taking a further step toward accurate arbitrary-shaped scene text detection[J]. IEEE, 2020: 11750-11759.
- [4] Peng S, Jiang W, Pi H, et al. Deep snake for real-time instance segmentation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 8533-8542.
- [5] Yu F, Wang D, Shelhamer E, et al. Deep layer aggregation[J]. arXiv, 2017.
- [6] Zhou X, Wang D, Krhenbühl, et al. Objects as points [J]. arXiv, 2019.

作者简介: 袁 梦, 女, 1999 年生, 硕士研究生。研究方向为深度学习、缺陷检测。苏工兵 (通讯作者), 男, 1967 年生, 博士, 教授。研究方向为视觉检测与视觉伺服控制。