

基于改进 CenterNet 的 AFP 铺层表面缺陷检测

王 璇¹, 康 硕¹, 朱伟东^{1,2,3}

- (1. 浙江大学 机械工程学院, 浙江 杭州 310027;
2. 浙江大学 机械工程学院 流体动力与机电系统国家重点实验室, 浙江 杭州 310027;
3. 浙江大学 机械工程学院 浙江省先进制造技术重点实验室, 浙江 杭州 310027)

摘 要: 针对利用可见光图像检测 AFP 铺层表面缺陷受光源条件差、预浸纱纹理对比度低等因素影响, 检测结果不理想, 提出一种基于改进 CenterNet 的 AFP 铺层表面红外图像缺陷检测方法, 提高 AFP 铺层表面缺陷检测性能。首先, 针对 CenterNet 模型参数数量过多而工控机硬件配置有限的问题, 提出利用基于 ASFF 的轻量级 MobileNetV3 作为骨干网络, 构建轻量级 anchor-free 检测模型 AFP-CenterNet, 减少网络参数数量的同时降低计算机存储资源占用率。然后, 针对高斯核函数带宽参数的求解, 提出一种根据 ground-truth bounding box 长宽比自适应调整带宽参数的方法, 减小负样本数量, 降低网络模型的损失误差。实验结果表明, 改进后的 AFP-CenterNet 在 AFP 红外数据集上的 AP 为 90.2%, 模型内存容量为 12.9 MB, 使用 GPU 加速时单张检测时间为 52 ms。和原有的 CenterNet 骨干网络相比, AFP-CenterNet 检测精度略差于 DLA-34, 和 ResNet-101 相当, 比 ResNet-18 高 7.7%, 内存占用率和 DLA-34、ResNet-101、ResNet-18 相比分别降低 83.2%、93.6% 和 78.6%。和 SSD、YOLOv3 相比, AFP-CenterNet 模型的 AP 分别提升 9.6% 和 8.3%, 内存占用量降低 85.1% 和 94.5%。在不使用 GPU 加速的条件下, 改进后的 AFP-CenterNet 的检测速度和 CenterNet、SSD、YOLOv3 相比提高近一倍, 具有明显的检测优势。

关键词: 自动纤维铺放 (AFP); 红外图像; 缺陷检测; CenterNet; AFP-CenterNet
中图分类号: TP391 **文献标志码:** A **DOI:** 10.3788/IRLA20210011

Defect detection of laminated surface in the automated fiber placement process based on improved CenterNet

Wang Xuan¹, Kang Shuo¹, Zhu Weidong^{1,2,3}

- (1. School of Mechanical and Engineering, Zhejiang University, Hangzhou 310027, China;
2. State Key Laboratory of Fluid Power and Mechatronic Systems, College of Mechanical Engineering, Zhejiang University, Hangzhou 310027, China;
3. Key Laboratory of Advanced Manufacturing Technology of Zhejiang Province, College of Mechanical Engineering, Zhejiang University, Hangzhou 310027, China)

Abstract: To solve the problem that the low defect detection accuracy on fiber laminated surface in Automated Fiber Placement (AFP) process based on visible images influenced by poor light source, low texture contrast of prepreg and other factors, a method for defect detection of laminated surface infrared images in AFP process based on improved CenterNet was proposed to improve defect detection performance on laminated surface in AFP process. First of all, due to the limit on hardware configuration of IPC, and large amounts of parameters on CenterNet model, lightweight MobileNetV3 network based on ASFF was utilized as the backbone network of

收稿日期: 2021-01-12; 修订日期: 2021-02-09

作者简介: 王璇, 女, 硕士生, 主要从事机器视觉、目标识别方面的研究。

导师简介: 朱伟东, 男, 教授, 博士生导师, 博士, 主要从事机器视觉、复合材料缺陷检测方面的研究。

AFP-CenterNet model to construct an anchor-free and lightweight detection model and reduce the number of network parameters and the occupancy of storage resources. Then, as for solving the bandwidth parameters of Gaussian kernel function, a method of adaptive adjustment of bandwidth parameters according to the aspect ratio of ground-truth bounding box was proposed to reduce the number of negative samples and loss error. Experimental results reveal that the improved AFP-CenterNet owns 90.2% AP in defect detection accuracy on the AFP infrared data set, 12.9 MB in model memory capacity, and 52 ms in detection time of a single sheet. Compared with the original backbone of CenterNet, detection accuracy of AFP-CenterNet is slightly worse than that of DLA-34, almost same with that of ResNet-101 and 7.7% higher than that of ResNet-18. Moreover, compared with DLA-34, ResNet-101 and ResNet-18, the model capacity of AFP-CenterNet decreased by 83.2%, 93.6% and 78.6% respectively. As for comparison with typical anchor-based network such as SSD and YOLOv3, AFP-CenterNet owns higher detection accuracy with specific 9.6% and 8.3%, and lower model capacity respectively reduced by 85.1% and 94.5%. Time spent on defect detection of AFP-CenterNet is nearly half that of CenterNet, SSD and YOLOv3 without using GPU to accelerate.

Key words: Automated Fiber Placement(AFP); infrared images; defect detection; CenterNet; AFP-CenterNet

0 引言

碳纤维复合材料因具有优越的力学性能和化学特性,广泛应用于航空航天、体育器械、纺织、化工机械和汽车工业等领域^[1-3]。特别地,在航空航天领域,碳纤维复合材料的用量占比与日俱增,在波音 787 和空客 A350XWB 为代表的大型客机中复合材料的用量已经占到飞机结构重量的 50%,整个机身、机翼结构几乎全部采用了碳纤维复合材料^[4]。自动纤维铺放 (Automated Fiber Placement, AFP) 技术的发展为实现大型碳纤维复合材料结构件自动化和数字化制造提供了有效保障。铺放过程中受固结力、铺层速度、固化速度和融化速度等参数的影响,铺层表面会产生缺丝、间隙、气泡、扭转、外来物等缺陷,影响成型构件的力学性能,带来安全隐患^[5]。

传统地,在铺好每一层预浸纱后,操作人员主要通过目视检查来保证铺层表面质量,但是预浸纱之间的低视觉对比度特性导致人工检查时耗费大量时间定位缺陷,并且辨别的种类可能存在误差,据统计铺放过程中进行铺层表面检查和机器维修的时间高达 30%^[6],研究高效率和高精度的预浸纱缺陷视觉检测方法是提高 AFP 系统自动化程度的关键技术之一。实现缺陷精准分类和定位不仅依靠无损检测技术,还需要可靠的图像处理算法。国内,南京航空航天大学文立伟等^[7]研究基于机器视觉与 UMAC 的自动铺丝成型构件缺陷检测闭环控制系统,对采集到的预浸纱铺层表面图像进行降噪处理提高图像质量,然后使用

边缘提取算法计算预浸纱间隙和重叠的尺寸大小,将数据传输给运动单元进行反馈控制,以保证铺丝精度。魏天舒^[8]研究用于检测预浸带缺陷的图像处理算法。结合分数阶微分和高斯滤波器进行图像预处理,保留缺陷信息的同时去掉噪声干扰;改进 Otsu 算法分割图像并使用 Canny 算子提取缺陷边缘;利用灰度共生矩阵的纹理特征提取预浸带图像中的缺陷特征并进行缺陷分类。国外, Berend Denkena 等^[9]提出结合红外热像仪和图像处理算法监控 AFP 铺放过程。通过评估压辊后面的感兴趣区域并应用边缘检测算法,提取和监控丝束的几何形状及其位置。铺放层压板不均匀截面温度与其周围表面温度不同,这些热点或冷点表示异常如架桥或异物缺陷,通过动态阈值可以检测到热点和冷点。Carsten Schmidt 等^[10]根据铺放过程中产生的温度差,提出一种基于红外热成像的 AFP 缺陷监控系统,可以定位丝束位置,发现某些温度异常,结合路径规划中的加工工艺可以判断缺陷种类。实验结果表明,该系统能够独立于先前铺放的层和纤维铺放方向定位每一铺层的铺放缺陷。

传统目标识别方法是先采用 SIFT 或 HOG 算子提取缺陷特征,然后使用 SVM 进行目标分类^[11]。这种方法对缺陷特征描述有限,且人工干预多,检测精度低。卷积神经网络的快速发展,为图像领域的分类、识别和分割等任务^[12-14]提供了更加有效的自动分析方法。Carsten Schmidt 等^[15]提出基于深度学习的无损检测方法用于对不同的 CFRP 预浸料热图进

行缺陷检测和分类。实验结果表明, ResNet-101 比提出的 CNN-2 网络的缺陷检测精度略好, 但 ResNet-101 网络架构复杂, 参数数量较多, 对目标进行分类也需要更长的时间。Christopher Sacco 等^[16]开发了基于机器视觉的 AFP 铺层表面缺陷检测系统 ACSIS, 可以实现缺陷的分类和定位并且可以得到尺寸信息。具体地, 采用改进的 ResNet 网络模型对图像进行语义分割, 产生一系列对应于不同种类的像素 blobs, 然后使用 MSA 算法在含有缺陷的像素点边界周围放置一个多边形, 记录多边形的顶点位置求得质心, 并记录缺陷类型。

不同于基于锚点的目标检测器, anchor-free 网络模型预测目标框的角点或是中心点, 不会产生大量的候选框, 网络结构简单, 保持高检测精度的同时处理速度更快。Hei Law 等^[17]提出的 CornerNet 将预测目标框的位置转化为预测目标框的左上角点和右下角点, 模型不需要设计锚点并生成大量多尺度的候选框, 极大地简化模型的同时保证较高的检测精度。Xingyi Zhou 等^[18]在 CornerNet 的基础上提出 ExtremeNet 模型, 先预测目标框的四个角点和中心点, 然后对角点和中心点进行分组, 进而求得目标框的尺寸信息。2019 年, Xingyi Zhou 等^[19]提出 CenterNet 网络模型, 根据骨干网络生成的关键点热力图预测目标中心点, 然后直接从中心点对应的特征图中回归出其他属性, 例如目标尺寸、3D 范围、方向和位姿等。

文中研究基于改进 CenterNet 的 AFP 铺层表面缺陷检测方法。首先, 针对 CenterNet 骨干网络参数数量多、检测速度受计算机硬件配置限制的问题, 提出结合轻量级 MobileNetV3 网络和 ASFF 自适应特征融合作为骨干网络, 构建 AFP-CenterNet 检测模型。然后提出一种根据 ground-truth bounding box 长宽比自适应调整高斯核函数带宽参数的方法, 有效减少负样本数量, 降低训练时的损失误差。最后, 搭建实验平台采集 AFP 铺层表面红外图像, 将 AFP-CenterNet 和 CenterNet、SSD、YOLOv3 网络模型分别进行训练。实验结果表明, 改进的 AFP-CenterNet 模型在保持较高缺陷检测精度的同时, 极大地减少模型参数数量, 降低计算机存储资源占用率。自动纤维铺放加工时, 工控机硬件配置有限, AFP-CenterNet 具有明显的检测优势。

1 AFP 铺层表面缺陷检测网络模型

1.1 CenterNet 简介

CenterNet 网络的核心思想是通过关键点热力图预测目标中心点, 然后从关键点对应的其他特征图中回归出目标的其他属性, 例如目标尺寸、3D 位置和位姿等, 图 1 所示是 CenterNet 网络在目标检测任务中的预测输出。相较于基于锚点的深度学习目标检测器, CenterNet 网络模型不会生成大量的候选框, 也不需要非极大值抑制这类后处理, 网络结构简单, 保持高检测精度的同时处理速度更快。




图 1 (a) 关键点热力图; (b) 关键点偏置; (c) 目标尺寸

Fig.1 (a) Keypoint heatmap; (b) Keypoint offset; (c) Object size

假设输入图像为 $I \in R^{W \times H \times 3}$, 其中 W 和 H 分别是图像的宽度和高度, 经过 CenterNet 骨干网络后输出 R 倍下采样特征图, 特征图大小为 $\frac{W}{R} \times \frac{H}{R}$, 然后分为三路分别预测目标关键点、目标中心点偏置和目标框尺寸。图 2 所示是以 ResNet-18 为骨干网络的 CenterNet

网络结构示意图, 其中输入图像为 $512 \times 512 \times 3$, 三个分支共享骨干网络输出的特征图 $128 \times 128 \times 64$ 。经过一系列卷积操作后得到 C 类关键点热力图 \hat{Y} 、两张预测中心点偏置的特征图 \hat{O} 和两张预测目标尺寸的特征图 \hat{S} 。网络最后输出的特征张量为 $128 \times 128 \times (C+4)$ 。

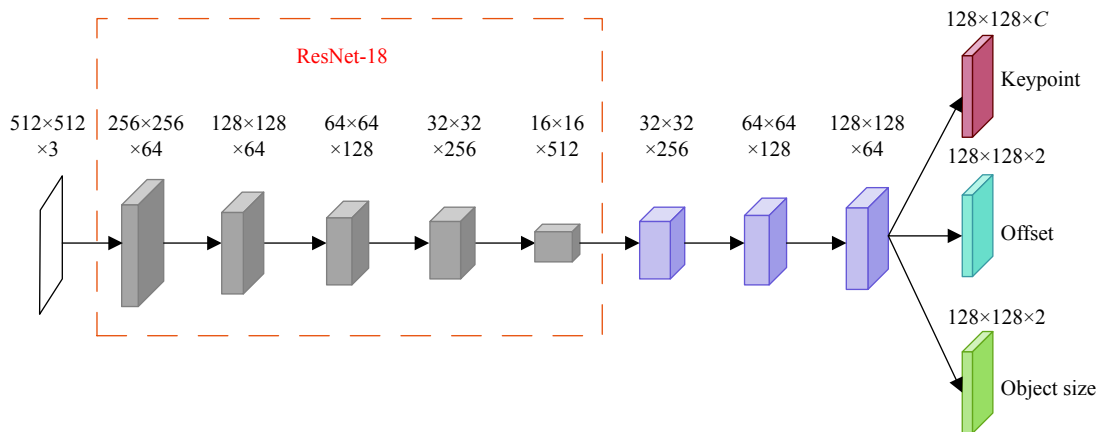


图 2 以 ResNet-18 为骨干网络的 CenterNet 网络结构示意图

Fig.2 Schematic diagram of CenterNet network with ResNet-18 as backbone network

预测关键点坐标时,提取热力图 $\hat{Y} \in [0, 1]^{W \times H \times 3}$ 上的峰值点,最大个数为 100 个。具体地,遍历热力图,将当前点和相邻的 8 个点的热力值进行比较,如果该点热力值大于等于其相邻的 8 个连接点,则认为该点是关键点。假设 \hat{P}_c 为热力图中检测到的种类 C 的关键点集合, $\hat{P} = \{(\hat{x}_i, \hat{y}_i)\}_{i=1}^n$ 表示集合中的一个关键点。每个关键点的在原始图像中的位置用整数坐标 (x_i, y_i) 表示, $\hat{Y}_{x_i, y_i, c}$ 表示当前点的置信度,则目标框的坐标为:

$$(\hat{x}_i + \delta\hat{x}_i - \hat{w}_i/2, \hat{y}_i + \delta\hat{y}_i - \hat{h}_i/2, \hat{x}_i + \delta\hat{x}_i + \hat{w}_i/2, \hat{y}_i + \delta\hat{y}_i + \hat{h}_i/2) \quad (1)$$

式中: $(\delta\hat{x}_i, \delta\hat{y}_i) = \hat{O}_{\hat{x}_i, \hat{y}_i}$ 是预测的关键点 (\hat{x}_i, \hat{y}_i) 对应的偏置误差; $(\hat{w}_i, \hat{h}_i) = \hat{S}_{\hat{x}_i, \hat{y}_i}$ 表示关键点对应的目标框尺寸。每个目标有且只有一个中心点,该中心点只和像素位置有关,不存在锚点的重叠,不需要使用非极大值抑制处理,当目标的中心点坐标和目标框尺寸已知,就可以准确分类和定位目标,完成检测任务。

1.2 AFP-CenterNet 网络

1.2.1 ASFF 简介

特征金字塔 (Feature Pyramids Network, FPN)^[20] 是目前解决目标检测多尺度变化问题的常用方法。

但 FPN 只是对不同特征层尺寸调整一致后进行简单的累加,不同特征尺度之间的不一致导致融合特征图噪声大,效果不佳。ASFF(Adaptively Spatial Feature Fusion, ASFF)^[21] 通过参数自适应调整不同特征层的融合比例,在空间上过滤冲突信息以抑制梯度反向传播时的不一致,改善特征比例不变性,并且降低推理开销。ASFF 可以被应用于任何 FPN 形式的网络中,其融合方式的过程是可微分的,适用于反向传播,且实现方式简单、计算量小。

以三层 ASFF 结构为例, L1、L2 和 L3 表示不同尺度的特征层,经过融合后得到 y^3 , 融合后的特征图尺寸和 L3 特征图尺寸一致。 $X^{1 \rightarrow 3}$ 表示将 L1 特征尺寸调整至和 L3 特征尺寸一致, L1、L2 和 L3 对应的特征融合系数为 α^3 、 β^3 和 γ^3 。则 ASFF-3 对应的融合后的特征层如公式 (2) 所示:

$$y^3 = \alpha^3 \cdot X^{1 \rightarrow 3} + \beta^3 \cdot X^{2 \rightarrow 3} + \gamma^3 \cdot X^{3 \rightarrow 3} \quad (2)$$

网络学习融合系数的过程如图 3 所示, 首先将 L1 和 L2 特征层尺寸调整到 L3 特征图大小, 得到 $X^{1 \rightarrow 3}$ 和 $X^{2 \rightarrow 3}$, L3 特征层即为 $X^{3 \rightarrow 3}$, 然后分别经过 1×1 卷积层将每层通道数压缩至 16, 通过 concat 沿通道方向拼接, 接着再经过一个通道为 3 的 1×1 卷积层, 利用




图 3 网络学习融合系数的过程

Fig.3 Process of network learning fusion coefficient

Softmax 操作使融合权重系数在 [0,1] 之间,最后得到 L1、L2 和 L3 对应的融合系数。

1.2.2 AFP-CenterNet 网络

MobileNetV3^[22] 是一种轻量型深度卷积网络,结合了 MobileNetV1^[23] 提出的深度可分离卷积和 MobileNetV2^[24] 提出的具有线性瓶颈的反向残差结构,并引入了基于注意力机制的压缩和激励模块 (Squeeze and Excitation block, SE-block)。深度可分离卷积将标准的卷积操作分解为深度卷积和逐点卷积,参数数量是标准卷积操作的 $\frac{1}{N} + \frac{1}{D_k^2}$, N 为卷积核通道数, D_k 表示卷积核大小。反向残差结构先扩展输入特征图的通道,然后利用深度可分离卷积进行下采样缩小特征图尺寸,最后再缩减通道,能够增强网络模型的表达能力。SE-Block 首先利用全局池化生成通道统计信息进行压缩操作,将全局空间信息压缩为一个通道描述符,然后经过两个全连接层,最后使用 Sigmoid 激活函数进行激活操作,使得网络中有效特征权重增大,无效特征权重减小,加强网络学习能力。

和其他深度卷积神经网络相比, MobileNetV3 通过使用深度可分离卷积极大的减少网络参数数量,降低模型内存占用率,适用于计算机硬件配置有限的工业加工现场。针对目标检测任务中的多尺度变化问题,使用自适应特征融合提高网络模型的表达能力,改善特征比例不变性。

结合 MobileNetV3-Large 和 ASFF 作为 AFP-CenterNet 骨干网络,模型结构示意图如图 4 所示。去除 MobileNetV3-Large 网络最后的平均池化层和 1×1 卷积层,得到 4 倍下采样特征图 C2、8 倍下采样特征图 C3、16 倍输出特征图 C4 和 C5 和 32 倍下采样特征图 C6。在 FPN 融合的基础上,进一步结合 ASFF,输出 4 倍下采样特征图 P2,然后分为三路,分别经过一系列卷积操作后得到六张关键点热力图预测目标中心点位置、两张特征图预测目标中心点偏置和两张特征图预测目标框大小。

为了提高 AFP-CenterNet 网络对目标几何变换的建模能力,在 M6、M5、M3 上采样之前先使用可变形卷积 DCNv2 将通道分别变化为 112、40 和 24,在合理的范围内增大目标感受野。然后对浅层特征 M6、M5、M3 利用转置卷积上采样后分别和同通道同尺寸的深层特征层 C5、C3 和 C2 相加得到 M5、M3 和

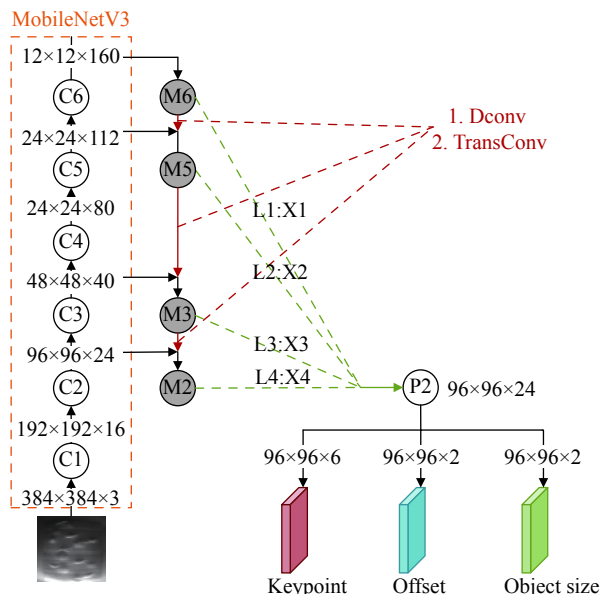


图 4 AFP-CenterNet 网络结构示意图

Fig.4 Structure diagram of AFP-CenterNet network

M2, 这就是 FPN 结构。

在此基础上对 FPN 融合后得到的特征图进一步使用 ASFF 融合。ASFF 一共有 4 层,分别是 32 倍下采样特征图 M6、16 倍下采样特征图 M5、8 倍下采样特征图 M3 和 4 倍下采样特征图 M2,在进行加权相加时 L1~L4 层的特征图尺寸大小和通道维度必须相同,需要对不同层的特征图做上采样并调整通道数。采用的方式是先通过 1×1 可变形卷积将 M6、M5、M3 调整至与 M2 通道数一致,再用转置卷积分别将 M6、M5、M3 进行 8 倍上采样、4 倍上采样和 2 倍上采样得到和 M2(X4) 同尺寸和通道维度的 X1、X2 和 X3,四层对应的特征权重系数分别为 α 、 β 、 γ 和 δ ,ASFF 融合后得到特征图 P2,如公式 (3) 所示。融合系数在网络训练时利用反向传播求得。

$$P2 = \alpha^4 \cdot X^{1-4} + \beta^4 \cdot X^{2-4} + \gamma^4 \cdot X^{3-4} + \delta^4 \cdot X^{4-4} \quad (3)$$

1.3 损失函数

模型训练时的损失由三部分构成:中心点预测损失 L_k 、中心点偏置损失 L_{off} 和目标框尺寸预测损失 L_{size} ,如公式 (4) 所示:

$$L_{det} = L_k + \lambda_{off} L_{off} + \lambda_{size} L_{size} \quad (4)$$

式中: λ_{off} 和 λ_{size} 分别为中心点偏置损失 L_{off} 和目标框大小损失 L_{size} 的权重系数,文中 λ_{off} 取 1, λ_{size} 取 0.1。

训练前,需要将 GT box(ground-truth bounding box)通过公式 (5) 所示的高斯核函数映射到不同种类

对应的热力图 Y 上, 作为训练时理想的目标中心点位置。采用公式 (6) 所示的焦点损失作为计算预测目标关键点的损失函数。其中, α 和 β 是超参数, 分别取 2 和 4, N 表示每一类热力图中的关键点数量。

$$Y_{\text{yxc}} = \exp\left(-\frac{(x-\tilde{p}_x)^2 + (y-\tilde{p}_y)^2}{2\sigma_p^2}\right) \quad (5)$$

$$L_k = -\frac{1}{N} \sum_{\text{yxc}} \begin{cases} (1-\hat{Y}_{\text{yxc}})^\alpha \log(\hat{Y}_{\text{yxc}}) & \text{if } Y_{\text{yxc}} = 1 \\ (1-Y_{\text{yxc}})^\beta (\hat{Y}_{\text{yxc}})^\alpha \log(1-\hat{Y}_{\text{yxc}}) & \text{otherwise} \end{cases} \quad (6)$$

骨干网络输出的特征图尺寸相比于原始输入图像的尺寸缩小了 R 倍, 目标关键点的坐标位置是由关键点热力图 \hat{Y}_{yxc} 预测所得, 计算目标中心点在原始输入图像上的位置时, 会因整数和浮点数之间的精度转换问题产生误差。通过添加关键点位置偏差损失 $\hat{O} \in R^{W' \times H' \times 3}$ 可以补偿精度转换带来的误差。同一种类的所有目标关键点使用相同的偏置损失函数, 采用如公式 (7) 所示的最小绝对值误差函数进行训练。

$$L_{\text{off}} = \frac{1}{N} \sum_p \left| \hat{O}_{\tilde{p}} - \left(\frac{p}{4} - \tilde{p} \right) \right| \quad (7)$$

式中: \tilde{p} 表示热力图 \hat{Y} 预测到的关键点; $\hat{O}_{\tilde{p}}$ 表示预测出来的偏置; p 指的是目标关键点 \tilde{p} 对应的实际目标框的真实中心点; 4 指的是下采样的倍数。

计算目标框尺寸大小损失时, 假设 $(x_1^{(k)}, y_1^{(k)}, x_2^{(k)}, y_2^{(k)})$ 是目标 k 的 GT box 坐标, 所属类别为 c_k , 中心点 p_k 的坐标为 $\left(\frac{x_1^{(k)} + x_2^{(k)}}{2}, \frac{y_1^{(k)} + y_2^{(k)}}{2} \right)$ 。使用关键点热力图 \hat{Y} 去预测所有种类的中心点。在模型训练之前, 对每个目标 k 的尺寸进行回归, 计算出 $S_k = (x_2^{(k)} - x_1^{(k)}, y_2^{(k)} - y_1^{(k)})$ 。为了减少回归的难度, 使用 $\hat{S} \in R^{W' \times H' \times 3}$ 预测目标框尺寸, 最小绝对值误差作为损失函数, 如公式 (8) 所示:

$$L_{\text{size}} = \frac{1}{N} \sum_{k=1}^N |\hat{S}_{p_k} - S_k| \quad (8)$$

1.4 带宽参数优化

训练时需要先将真实目标框 GT box 映射到热力图上以便计算预测目标中心点时的损失, 但是不能只将 GT box 的中心点对应的热力值置为 1。图 5(a) 所示, 红色矩形框为标注好的 GT box, 但是绿色矩形框也能很好的包围目标。如果模型在检测时得到类似的框, 可以将其保留。于是 CenterNet 提出只要预测的关键点所对应的目标框和 GT box 的左上角点或右下角点在某一个半径为 r 的圆形内, 并且预测的目标框和 GT box 的交并比大于给定的阈值, 文中设为 0.7, 则这些点的热力值不直接置为 0, 采用如公式 (5) 所示的二维高斯核函数得到一个大于 0 小于 1 的热力值。

文中在此基础上提出结合使用椭圆筛选可行框, 将 GT box 映射到热力图上, 热力图上生成一个椭圆形, 椭圆的横轴和纵轴随着 GT box 尺寸进行变换。图 5 中的 (b) 和 (c) 是分别使用圆形和椭圆形将 GT box 映射到热力图上的情况。当目标的 GT box 长宽比较大 (大于 5) 或者比较小 (小于 0.2) 时, 如果使用圆形筛选可行的目标框, 热力图生成一个高斯圆, 会造成除了可靠的目标框之外还有大于 0 的热力值, 使用椭圆筛选可行的目标框可以保证椭圆中的每个点对应的目标框都是有效的、可靠的。

实际上除了 GT box 的中心点以外其他可行框都是负样本, 负样本会产生损失, 离 GT box 中心点越近的点的热力值越大, 产生的损失越小, 反之越大, 如果使用圆形去判断和筛选, 会造成负样本数量过多, 损失误差较大。



图 5 (a) GT box 和可行框; (b) 使用圆形筛选可行框得到的 GT box 热力图; (c) 使用椭圆筛选可行框得到的 GT box 热力图

Fig.5 (a) GT box and feasible boxes; (b) GT box heatmap obtained using a circular to filter feasible boxes; (c) GT box heatmap obtained using an ellipse to filter feasible boxes

根据 GT box 长宽比自适应调整高斯核函数中的带宽参数能够有效的减少负样本数量,降低损失误差。首先根据 GT box 的长宽比确定使用圆形预测还是使用椭圆预测,图 6(a) 所示是使用圆形预测时的情况,图 6(b) 所示是使用椭圆预测时的情况。在保证可行框和 GT box 的交并比大于 0.7 的前提下求解出最小的半径 r , 带宽参数 $\sigma_p = r/3$ 。

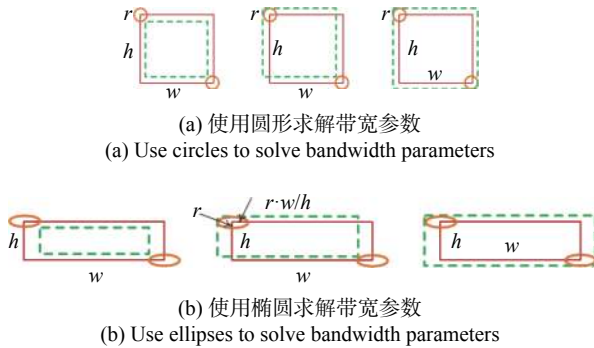


图 6 改进后的带宽参数求解方法

Fig.6 Improved bandwidth parameter solution method

2 数据采集和实验验证

2.1 采集 AFP 铺层表面红外图像

红外热成像的实质是将目标和背景之间的温度

差转换成红外图像中的像素差,拍摄的图像不受预浸纱表面纹理信息的干扰,光源也不会影响红外图像的成像效果,预浸纱缺陷目标和非缺陷背景之间的对比度明显优于可见光图像。AFP 红外数据采集平台采用脉冲激励红外热成像法,激励热源为卤素灯,加热灯功率为 2 000 W。根据实验,当两个灯源之间的距离为 0.6 m、角度为 20°时,采集到的图片效果最佳。相机型号是 Xenics 公司的 Gobi-640-GigE 长波红外相机,分辨率为 640×480,像元尺寸 17 μm,相机工作温度范围为 -40~60 °C,最大频率为 50 Hz,热灵敏度为 55 MK (30 Hz, 300 K, F/1)。数据采集平台如图 7(a) 所示。

受进给速度、固化速度、固结力和铺层速度等工作参数影响,铺放过程中常出现缺陷、间隙、搭接、架桥、扭转、褶皱、劈裂、外来物和气泡等缺陷,结合红外相机采集到的数据,文中主要研究如图 7(b) 所示的六种缺陷类型,包括外来物 (foreign objects)、间隙 (gap)、褶皱 (puckering)、气泡 (bubble)、扭转 (twist) 和缺丝 (missing tow)。红外图像中的架桥和丝束劈裂等缺陷对比度也很明显,但现场铺放过程中这些缺陷出现的频率较小,为了保证模型学习的准确性,文中不做研究。

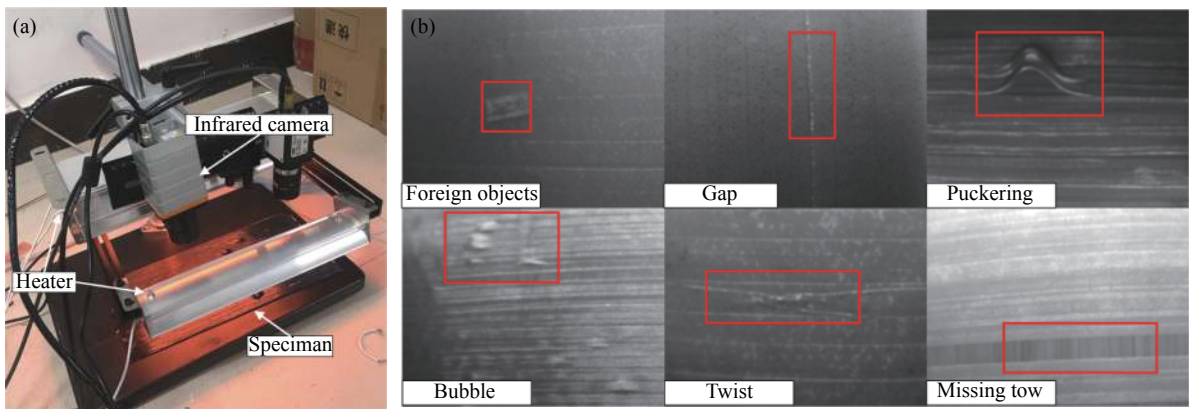


图 7 (a) 数据采集平台; (b) 六种 AFP 铺层表面缺陷红外图像

Fig.7 (a) Data acquisition platform; (b) Infrared images of six typical kinds of AFP laminated surface defects

总共采集 1 500 张 AFP 铺层表面红外图像,部分数据是在自动纤维铺放过程中采集,但是由于现场铺放加工时产生的缺陷数量有限,于是人为地铺放了一部分缺陷,其中含有缺陷的图像共 838 张。对 AFP 红外图像进行标定后,统计六类缺陷个数分别为:缺丝 (1 053), 间隙 (1 227), 扭转 (1 431), 褶皱 (957), 气泡

(1 862), 外来物 (656)。将 1 500 张标定好的红外图像用作后续训练检测模型的数据集。

2.2 模型训练环境和参数设置

数据集制作时采用 LabelImg 对 AFP 红外图像进行标注,得到标准 COCO 格式的 AFP 红外数据集。将数据集划分为三类:训练集、验证集和测试集,比例

为 7 : 2 : 1, 即训练集 1050 张, 验证集 300 张, 测试集 150 张。验证集用来观察 AFP-CenterNet 网络在训练过程中的拟合情况, 如果出现过拟合需要立即停止训练。

采用 Windows10 操作系统, 计算机内存为 64G, 处理器型号为 Intel Core i7-9700K, 显卡型号为 NVIDIA GeForce RTX 2080, 深度学习框架使用 Pytorch 1.2.0, CUDA 10.0, CUDNN 7.4.0。

使用小批量随机梯度下降法来训练模型, 批大小设置为 50, 进行小批量训练, 初始学习率为 1.25×10^{-4} , 随着迭代次数增多不断的降低学习速率, 动量设置为 0.9, 训练周期为 140 个 epoch, 每隔 5 个 epoch 进行一次验证。骨干网络输出的特征图进行 4 倍下采样, 需要将输入图像尺寸预处理成 384×384 , 则输出热力图的尺寸大小为 96×96 , 对输入的图像, 使用随机翻转、缩放、裁剪进行数据增强。

2.3 评价指标

对于 AFP 铺层表面缺陷检测性能, 需要考虑网络模型的检测精度和速度, 同时由于生产加工时工控机硬件配置受到限制, 需要考虑网络模型占用的计算机内存。

AFP 数据集整理成标准 COCO 数据集格式, 因此采用 COCO 数据集的 AP、AP50、AP75 作为检测精度指标。COCO 数据集中所有的 AP (Average Precision) 默认为 mAP (mean Average Precision)。预测样本时共有四种情况: FP (False Positive) 表示预测出一个不存在的物体、FN (False Negative) 表示没有预测到存在的物体、TP (True Positive) 表示正确预测到存在的物体、TN (True Negative) 表示算法正确预测出背景。Precision 表示符合要求的正确识别物体的个数占总识别出的物体个数的百分数, 如公式 (9) 所示:

$$P = \frac{TP(t)}{TP(t) + FP(t)} \quad (9)$$

式中: t 表示预测目标框和 GT box 的交并比值, AP50 表示 $t = 0.5$ 。

检测速度采用单帧检测时间和每秒检测的帧数 (Frames Per Second, FPS) 作为评价指标。

3 实验结果与分析

训练时, AFP-CenterNet 网络总共迭代 140 个 epoch, 模型损失和迭代次数之间的趋势变化如图 8 所示。模型在迭代到第 30 个 epoch 时损失值的下降幅

度迅速减小, 损失值小于 1.5, 进入平缓区。迭代次数达到 60 次, 损失值开始小于 1, 在迭代次数达到 80 时, 损失值基本保持不变, 并且训练损失和验证损失基本相等。以上结果表明, AFP-CenterNet 模型的损失值能够在一定的迭代次数内收敛, 网络能够达到预期的训练效果, 具有稳定性。




图 8 损失值变化曲线图

Fig.8 Graph of changes in loss value

分别以 DLA-34, ResNet-18 和 ResNet-101 作为 CenterNet 的骨干网络和文中提出的 AFP-CenterNet 网络模型进行训练, 使用标准 COCO 数据集的评价指标, 在 AFP 红外数据集上的检测结果对比情况如表 1 所示。

从表 1 数据可知, AFP-CenterNet 网络模型的检测精度 AP 能够达到 90.2%, 略低于以 DLA-34 为骨干网络的 CenterNet 网络, 但是和 ResNet-101 基本持平, 并且和 ResNet-18 相比高出 7.7%。虽然以 DLA-34 和 ResNet-101 为骨干网络时 CenterNet 网络的检测精度略高于 AFP-CenterNet, 但是检测速度比 AFP-CenterNet 将近慢了一倍。此外, AFP-CenterNet 网络模型容量和以 DLA-34、ResNet-101、ResNet-18 为骨干网络的 CenterNet 网络模型相比分别降低了 83.2%、93.6% 和 78.6%, 极大地降低了计算机硬件和存储资源的占用情况。

为了验证 anchor-free 算法相比于基于锚点预测候选框的检测算法具有更好的性能, 文中还分别使用了 SSD 和 YOLOv3 作为单端检测的典型算法和 AFP-CenterNet 进行比较, 在 AFP 红外数据集上的检测结果如表 2 所示。

分析表 2 中的数据可知, 和 SSD、YOLOv3 相比, AFP-CenterNet 检测精度分别高出 9.6% 和 8.3%。基于中心点预测目标能够有效的避免基于锚点预测候选框时计算量过大、非极大值抑制操作需要设置阈值等影响网络处理速度和检测精度的操作。和 SSD、

表 1 CenterNet 和 AFP-CenterNet 在 AFP 红外数据集上的检测结果

Tab.1 Detection results of CenterNet and AFP-CenterNet on AFP infrared data sets

Network model	AP	AP50	AP75	Time/ms	FPS	Memory/MB
CenterNet(DLA-34)	0.727	0.926	0.753	81	12.3	77.0
CenterNet(ResNet-101)	0.693	0.904	0.728	93	10.7	204.0
CenterNet(ResNet-18)	0.626	0.825	0.647	31	32.2	60.3
AFP-CenterNet(MobileNetV3+ASFF)	0.694	0.902	0.731	42	23.8	12.9

表 2 不同网络模型在 AFP 红外数据集上的检测结果

Tab.2 Detection results of different network models on AFP infrared data sets

Network model	AP50	Model memory/MB
SSD	0.806	86.5
YOLOv3	0.819	235.0
AFP-CenterNet	0.902	12.9

YOLOv3 相比, AFP-CenterNet 网络模型的内存容量仅为 12.9 MB, 分别降低了 85.1% 和 94.5%。

实际工业生产中, 大多数工控机硬件配置有限, 尤其是不具有 GPU 加速条件, 这种情况下卷积神经网络模型的处理速度受到限制, 需要在仅有 CPU 的硬件条件下完成 AFP 铺层表面缺陷检测任务。表 3 所示是仅使用 CPU 处理时, 不同网络模型在 AFP 红外数据集上的检测结果。


表 3 不同网络模型在 CPU 环境下的检测速度

Tab.3 Detection speed of different network models only using CPU

Network model	Time/ms	FPS
SSD	537	1.8
YOLOv3	451	2.2
CenterNet(ResNet-101)	425	2.3
AFP-CenterNet	235	4.2


分析表 3 中的数据可知, 和 SSD、YOLOv3、CenterNet(ResNet-101) 相比, AFP-CenterNet 在 CPU 环境下, 单张检测速度分别高出 302 ms、216 ms 和 190 ms。在仅有 CPU 计算环境下与 SSD, YOLOv3 和 CenterNet (ResNet-101) 相比, AFP-CenterNet 具有明显的检测优势。

图 9 所示是 AFP-CenterNet 网络模型在 AFP 红外



(a) 原红外图像
(a) Original infrared image

(b) 红外图像检测结果
(b) Detection results of infrared image



(c) 六种缺陷对应的关键点热力图: 从左至右依次是间隙、缺丝、扭转、气泡、褶皱、外来物
(c) Keypoint heatmap corresponding to the six kinds of defects: gap, missing tow, twist, bubble, puckering, foreign objects

图 9 单张红外图片检测结果

Fig.9 Detection results of single frame infrared image

数据集上的单帧检测结果。图 9(c) 是六种表面缺陷对应的关键点热力图, 从左至右, 依次是间隙、缺失、扭转、气泡、褶皱和外来物, 表示此红外图像中含有的六种缺陷数量分别为 1、1、5、2、7 和 0。

4 结 论

针对利用可见光图像检测 AFP 铺层表面缺陷时受光照条件差、预浸纱纹理相似度高、像素对比度低等因素影响, 缺陷检测精度低, 提出一种基于改进 CenterNet 的 AFP 铺层表面红外图像缺陷检测方法。考虑 CenterNet 参数数量庞大而工控机硬件配置有限, 文中结合轻量级网络 MobileNetV3 和 ASFF 自适应特征融合作为骨干网络, 构建轻量级 anchor-free 检测模型 AFP-CenterNet, 保持高检测精度的同时极大地减少网络参数数量、降低内存占用率。提出一种根据 GT box 长宽比自适应调整高斯核函数带宽参数大小的方法, 有效减少负样本数量, 降低训练 AFP-CenterNet 网络的损失误差。实验结果表明, AFP-CenterNet 和 CenterNet 相比在保持高检测精度的同时, 极大地降低网络模型内存占用量, 减少处理时间。和基于锚点的 SSD、YOLOv3 网络相比, AFP-CenterNet 具有高检测精度优势。实际工业生产时工控机硬件配置有限, 在不使用 GPU 加速的条件下, AFP-CenterNet 的检测速度近乎于 SSD、YOLOv3 和 CenterNet(ResNet-101) 的一半, 为投入工业生产时检测 AFP 铺层表面缺陷提供了新的思路。

参考文献:

- [1] Li Wei, Guo Quanfeng. Application of carbon fiber composites to cosmonaut fields [J]. *Chinese Optics*, 2011, 4(3): 201-212. (in Chinese)
- [2] Bellini Costanzo, Di Cocco Vittorio, Iacoviello Francesco, et al. Performance evaluation of CFRP/Al fibre metal laminates with different structural characteristics [J]. *Composite Structures*, 2019, 225: 111117.
- [3] Forintos Norbert, Czigány Tibor. Multifunctional application of carbon fiber reinforced polymer composites: Electrical properties of the reinforcing carbon fibers-A short review [J]. *Composites Part B*, 2019, 162: 331-343.
- [4] Brüning J, Denkena B, Dittrich M A, et al. Machine learning approach for optimization of automated fiber placement processes [J]. *Procedia CIRP*, 2017, 66: 74-78.
- [5] Bakhshi Nima, Hojjati Mehdi. An experimental and simulative study on the defects appeared during tow steering in automated fiber placement [J]. *Composites Part A: Applied Science and Manufacturing*, 2018, 113: 122-131.
- [6] Rudberg Todd, Nielson Justin, Henscheid Mike, et al. Improving AFP cell performance [J]. *SAE International Journal of Aerospace*, 2014, 7(2): 317-321.
- [7] Wen Liwei, Song Qinghua, Qin Lihua, et al. Defect detection and closed-loop control system for automated fiber placement forming components based on machine vision and UMAC [J]. *Acta Aeronautica ET Astronautica Sinica*, 2015, 36(12): 3991-4000. (in Chinese)
- [8] Wei Tianshu. Research on image detection method for defects of composite prepreg tapes[D]. Jinan: Shandong University of Technology, 2018. (in Chinese)
- [9] Denkena Berend, Schmidt Carsten, Völtzer Klaas, et al. Thermographic online monitoring system for Automated Fiber Placement processes [J]. *Composites Part B*, 2016, 97: 239-243.
- [10] Schmidt Carsten, Denkena Berend, Völtzer Klaas, et al. Thermal image-based monitoring for the Automated Fiber Placement process [J]. *Procedia CIRP*, 2017, 62: 27-32.
- [11] Wang Bo, Tian Ruifeng. Judgement of critical state of water film rupture on corrugated plate wall based on SIFT feature selection algorithm and SVM classification method [J]. *Nuclear Engineering and Design*, 2019, 347: 132-139.
- [12] Yang Liping, MacEachren Alan M, Mitra Prasenjit, et al. Visually-enabled active deep learning for (Geo) text and image classification: A review [J]. *ISPRS International Journal of Geo-Information*, 2018, 7(2): 65.
- [13] Zhang Yuting, Sohn Kihyuk, Villegas Ruben, et al. Improving object detection with deep convolutional networks via bayesian optimization and structured prediction[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2015: 249-258.
- [14] Chen Liang-Chieh, Papandreou George, Kokkinos Iasonas, et al. DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(4): 834-848.
- [15] Schmidt Carsten, Hocke Tristan, Denkena Berend. Artificial intelligence for non-destructive testing of CFRP prepreg materials [J]. *Production Engineering*, 2019, 13(5): 617-626.
- [16] Sacco Christopher, Radwan Anis Baz, Anderson Andrew, et al. Machine learning in composites manufacturing: A case study of

- Automated Fiber Placement inspection [J]. *Composite Structures*, 2020, 250: 112514.
- [17] Law Hei, Deng Jia. CornerNet: Detecting objects as paired keypoints [J]. *International Journal of Computer Vision*, 2020, 128: 642-656.
- [18] Zhou Xingyi, Zhuo Jiacheng, Krähenbühl Philipp. Bottom-up object detection by grouping extreme and center points[C]// 2019 IEEE CVF Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2019: 850-859.
- [19] Zhou Xingyi, Wang Dequan, Krähenbühl Philipp. Objects as points [J]. *arXiv*, 2019: 1904.07850.
- [20] Lin Tsung-Yi, Dollár Piotr, Girshick Ross, et al. Feature pyramid networks for object detection[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2017: 936-944.
- [21] Liu Songtao, Huang Di, Wang Yunhong. Learning spatial fusion for single-shot object detection[J]. *arXiv preprint*, 2019: 1911.09516.
- [22] Howard Andrew, Sandler Mark, Chu Grace, et al. Searching for MobileNetV3[J]. *arXiv preprint*, 2019: 1905.02244.
- [23] Howard Andrew, Zhu Menglong, Chen Bo, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications[J]. *arXiv preprint*, 2017: 1704.04861.
- [24] Sandler Mark, Howard Andrew, Zhu Menglong, et al. MobileNetV2: Inverted residuals and linear bottlenecks[J]. *arXiv preprint*, 2018: 1801.04381.