

发动机转子叶片图像的边缘自动分割算法^{*}鲁思朋¹ 杨光² 马建徽² 赵纪元¹ 侯欣盟¹

(1.北京信息科技大学自动化学院 北京 100192;2.中国航发四川燃气涡轮研究院 成都 610500)

摘要: 转子叶片由于工作环境恶劣,十分容易发生形变,为了能监控转子叶片的边缘状态,提出了一种可以快速分割出转子叶片边缘的深度学习算法 CACNet,一种进行边缘检测的卷积神经网络。由于转子叶片高能 X 射线图像噪声多,动态模糊较大,且高能 X 射线透射带来的机匣内部结构伪影重叠在图像同一部分,导致待检测的图像质量极低。针对这种低质量的图像,使用改进过的自适应 Canny 算子来获得图像的粗略分割信息,用于辅助神经网络学习到更加准确的叶片边缘原始信息。模型采用多尺度的结构,能够将不同尺度下的分割信息进行融合,使得最终的结果更为清晰精准。为了进一步提高训练质量,引入了一种复合损失函数,可以精确地引导模型学习训练图像中正确的信息,使得最终模型在真实图像上表现的更加良好。实验结果表明,CACNet 具备了快速高效检测处转子叶片边缘的能力。

关键词: 深度学习;边缘检测;无损检测;神经网络

中图分类号: TP391.4;TN06 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Automatic segmentation algorithm for the edge of engine blade image

Lu Sipeng¹ Yang Guang² Ma Jianhui² Zhao Jiyuan¹ Hou Xinmeng¹

(1. School of Automation, Beijing University of Information Technology, Beijing 100192, China;

2. China Aviation Sichuan Gas Turbine Research Institute, Chengdu 610500, China)

Abstract: Rotor blades are very prone to deformation due to the harsh working environment. In order to monitor the edge state of rotor blades, this paper proposes a deep learning algorithm CACNet that can quickly segment the edge of rotor blades, a convolutional neural network for edge detection. Due to the high-energy X-ray image noise of the rotor blade, the dynamic blur is large, and the internal structure artifacts of the casing caused by high-energy X-ray transmission overlap in the same part of the image, resulting in extremely low image quality to be detected. For this low-quality image, the improved adaptive Canny operator is used to obtain the rough segmentation information of the image, which is used to assist the neural network to learn more accurate original information of the leaf edge. The model adopts a multi-scale structure, which can fuse the segmentation information at different scales, making the final result clearer and more accurate. In order to further improve the training quality, we also use a composite loss function, which can accurately guide the model to learn the correct information in the training image, so that the final model performs better on the real image. The experimental results show that the proposed algorithm has the ability to quickly and efficiently detect the edge of the rotor blade.

Keywords: deep learning; edge detection; nondestructive testing; neural network

0 引言

低压涡轮转子叶片是航空发动机的核心部件,在高温高压的工作环境下容易发生磨损和形变,这可能导致发动机性能下降,甚至影响发动机正常运行,进而造成安全隐患^[1]。为了解决这一问题,采用计算机视觉技术对发动机

中的低压涡轮转子叶片图像进行边缘检测,以精准识别低压涡轮转子叶片的边缘形态,评估其边缘磨损与形变情况,为叶片后续维护和优化提供科学依据。

目前,边缘检测领域的主流方法可分为传统算法和基于深度学习的算法。传统算法(如 Sobel、Canny 等经典边缘检测算子)因其计算成本低、延迟小等特点,仍广泛应用

于多个领域^[2]。然而,这些方法依赖于手动设定阈值,检测精度受限,难以适应复杂场景的需求。相比之下,随着深度学习技术的飞速发展,人们能够利用神经网络对图像进行像素级处理,从而实现更高精度、更具鲁棒性的边缘检测,为复杂场景下的精确识别提供了新的可能。

随着卷积神经网络(convolutional neural networks, CNN)的诞生,研究者们开始尝试将其应用于边缘检测任务。2015年,宾夕法尼亚大学的 Bertasius 等^[3]提出了 DeepEdge 算法,该方法利用多尺度架构的 CNN 网络进行边缘检测,采用双分支结构,将高层语义信息与低层局部信息结合,实现更加精准的边缘分割。DeepEdge 取得了与 Canny 等传统算子相当的性能,为深度学习在边缘检测领域奠定了基础。受此工作的启发,美国加州大学圣地亚哥分校的 Xie 等^[4]提出了 HED(holistically-nested edge detection)。HED 是一种端到端的深度学习边缘检测网络,引入了深度监督(deep supervision)策略,使 CNN 的不同层共同学习边缘信息,与传统方法相比,其检测精度大幅提升。

随着深度学习研究的深入^[5],越来越多高效、精确的边缘检测算法被提出。例如,基于 CNN 结构的 DexiNed(deep extreme inception network for edge detection)^[6]采用了 HED 的多尺度思想,并进一步挖掘不同尺度信息。DexiNed 通过不同尺寸的卷积核提取图像特征,在不增加计算量的情况下提升检测精度,同时引入不同损失函数分别监督模型的不同模块,使得模型输出的边缘图更加细致、精确。近年来,Transformer 在图像处理领域取得了卓越表现,使得许多研究者尝试将其应用于边缘检测任务。例如,中国科学技术大学的 Jie 等^[7]提出了一种基于 Transformer 结构的边缘检测网络 EdgeNAT(edge neighborhood attention transformer network)。EdgeNAT 采用扩张领域注意力作为编码器,并在解码器中结合空间和通道融合的注意力机制,最终以简洁的结构在 BSDS500 等数据集上取得了优异的成绩。此外,Ye 等^[8]提出了 DiffusionEdge,一种基于扩散模型(diffusion model)的边缘检测方法,利用噪声退化的过程学习图像中的细节,该网络能够生成极为细腻且精准边缘图像。

尽管深度学习技术不断发展,并催生出一系列性能卓越边缘检测网络^[9-10],但在高能 X 射线低压涡轮转子叶片图像上,这些模型的表现仍旧不尽如人意。由于图像质量较低,现有方法难以完整、清晰地从图像中分割出叶片的关键轮廓。为了解决这一问题,提出了一种结合 Canny 边缘检测模块与卷积块注意力机制(convolutional block attention module, CBAM)的多尺度 CNN 网络——CACNet(canny assist attention conventional network),以低压涡轮提升转子叶片边缘检测的准确性和鲁棒性。

1 总体结构

以 HED 网络为首的大量 CNN 模型证明了多尺度架构在边缘检测任务上的优秀能力^[11],受益于此,CACNet 沿用多尺度架构,并在原始的编码器与解码器结构中间加入 Neck 部分,增强模型对边缘的学习能力,因此模型包含 3 个主要模块:Encoder(编码器)、Neck(颈部)以及 Decoder(解码器),其网络结构如图 1 所示。

当一个图像 $f \in R^{H \times W \times 3}$ 被输入到 Decoder 中时,首先会进入解码模块 DBLOCK,每个 DBLOCK 的输出特征可以表示为式(1)。

$$f_{n+1} = \begin{cases} \frac{H_{f_n}}{2} \times \frac{W_{f_n}}{2} \times 16, & n = 0 \\ \frac{H_{f_n}}{2} \times \frac{W_{f_n}}{2} \times 2C, & n = 1, 2 \end{cases} \quad (1)$$

DBLOCK 主要由 Conv2d(卷积层)与 GELU(高斯误差线性单元激活函数),Conv2d 用于提取图像的边缘特征,GELU 在增强非线性能力的同时,标准化输出,使得学习到的特征整体均值与方差在 1 左右,该函数不仅能够解决训练过程中的梯度爆炸问题,还可以节省使用 Batch Normalization 层的开销^[12]。跳跃连接可以将低层语义向高层传输,让模型可以学习到不同尺度的边缘特征,使得模型对于噪声较大,运动模糊较为剧烈的图片的具有更强的鲁棒性。接着模型会将 Decoder 部分学习到的特征输入到 Neck 部分,特征会与自适应 Canny 模块提取的边缘信息在 CBAM 注意力模块中进行融合,CBAM 模块将混合的信息沿着两个独立的维度(通道和空间)顺序地推断注意力图,然后将注意力图乘以输入特征图来进行自适应特征细化,使得模型在学习阶段可以聚焦到边缘,抑制那些无用的信息。最终模型将学习到的特征向 Decoder 部分传递,Decoder 主要由 UBlock 和 ConCat 模块组成,UBlock 使用 Conv2d 来对 Neck 部分传递的信息进行学习,接着使用 ConvTranspose2d(转置卷积)来逐步生成边缘图像,每个阶段会输出一个边缘特征 $f_{out} \in H \times W \times 1$,ConCat 模块主要作用原理是利用 PixelShuffle 将不同阶段的边缘图像素重新排列至一张新的图像上,来得到最终的边缘图像,这样做可以充分利用不同阶段学习到的边缘知识,来生成所需要的最终图像。在 Decoder 部分,采用了多尺度架构,在不同阶段分别生成边缘图像,而不将其直接传递至下一阶段。随后,将各个阶段生成的边缘图像输入 ConCat 模块进行融合,从而整合浅层语义与深层语义信息。这种设计有效提升了模型的边缘检测能力,使得最终输出的边缘图像更加精准、细腻。

2 方法

由于图像数据集通常由人工标注,难免与真实边缘存在一定偏差,导致模型在训练过程中可能遗漏或误判部分

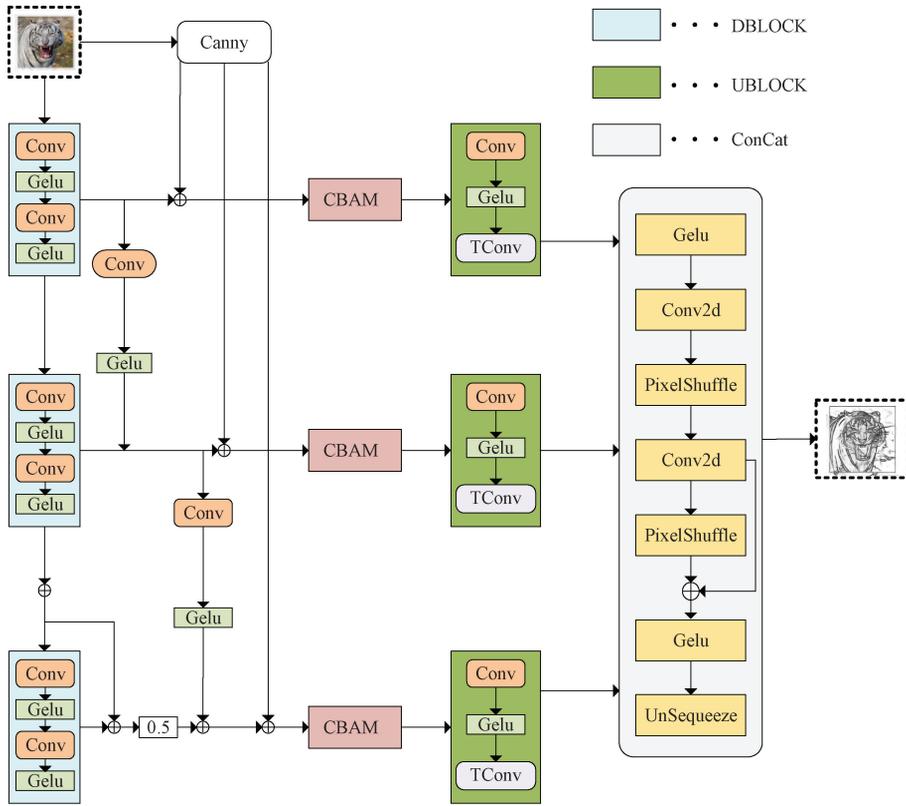


图1 CACNet 总体框架

Fig. 1 The overall framework of CACNet

边缘点。为改善这一问题,提出了一种自适应 Canny 模块来增强模型的边缘学习能力。该模块通过提供粗分割的边缘信息,使模型能够在 CBAM(卷积块注意力机制)中将编码器提取的特征与粗边缘信息进行融合与对比,在训练过程中使用提出的复合损失函数监督模型的训练过程,从而学习到更加精准的边缘特征,提高边缘检测的准确性。

2.1 自适应 Canny 模块

Canny 算子作为优秀的边缘检测器,常用于各类边缘分割任务。但其由于需要手动对图像设置高低阈值,缺乏灵活性,难以应用于不同图像的自动分割任务^[13]。针对此问题,提出了一种自适应 Canny 算法,能给自动为输入图像设置高低阈值,进而为模型提供粗边缘图像辅助信息。

自适应 Canny 算子首先会使用高斯滤波器 $G(x, y)$ 对图像 $I(x, y)$ 进行降噪,得到更加平滑的图像 $I_{Smooth}(x, y)$ 。

$$G(x, y) = \exp[-(x^2 + y^2)/2\sigma]/2\pi\sigma^2 \quad (2)$$

$$I_{Smooth}(x, y) = I(x, y) * G(x, y) \quad (3)$$

其中, σ 表示控制高斯滤波器的作用范围。

接着,使用一个一阶偏导算子来计算图像 $I_{Smooth}(x, y)$ 上每个像素点在水平方向的梯度值 G_x 和垂直方向的梯度值 G_y ,接着通过 G_x 和 G_y 来计算梯度幅值 G 和梯度方向 θ 来代替原始灰度值得到图像 $E(G, \theta)$ 。

$$G = \sqrt{G_x^2 + G_y^2} \quad (4)$$

$$\theta = \arctan\left(\frac{G_y}{G_x}\right) \quad (5)$$

其中, G 用来描述图像灰度值变化的强度矩阵, θ 用来描述灰度变化的方向矩阵。

在得到图像 $E(G, \theta)$ 后,依据非极大值抑制(non-maximum suppression, NMS)的思想,对图像进行边缘定位。该方法将梯度方向分割为一个 8 个方向的 3×3 方向矩阵,被检测像素点会根据其梯度方向,来与其对应梯度方向的邻格的像素点进行梯度幅值的比较,若被检测像素点大于邻格像素点,则被判定为边缘点。

最后,将图像 $E(G, \theta)$ 划分为多个子区间,统计每个子区间内的灰度值概率分布 $P(i)$,接着设置当前的边缘灰度值高阈值为 T_{high} ,如式(6)所示,通过阈值将像素点分为 C1 和 C2 两类。

$$G_{(i,y)} = \begin{cases} C1, & G_{(x,y)} \leq T_{high} \\ C2, & G_{(x,y)} > T_{high} \end{cases} \quad (6)$$

计算 C1 和 C2 两类像素点的概率与均值:

$$\begin{cases} \omega_1(T) = \sum_{i=0}^{T_{high}} P(i) \\ \omega_2(T) = \sum_{i=T_{high}+1}^{L-1} P(i) \end{cases} \quad (7)$$

$$\mu_1(T) = \frac{\sum_{i=0}^{T_{high}} i \cdot P(i)}{\omega_1(T_{high})} \quad (8)$$

$$\mu_2(T) = \frac{\sum_{i=T_{high}+1}^{L-1} i \cdot P(i)}{\omega_2(T_{high})} \quad (9)$$

其中, i 代表该灰度值所对应的像素点。

通过 ω 和 μ 来计算类间方差 ν :

$$\nu = \omega_1(\mu_1 - \mu_2)^2 + \omega_2(\mu_2 - \mu_1)^2 \quad (10)$$

ν 用来衡量在不同阈值 T_{high} 下, 两个类之间的区分度。

区分度越大则说明背景与边缘的差异越明显, 通过遍历所有可能的 T_{high} , 寻找到图像的最佳高阈值。 T_{high} 分割出图像中的明显边缘, 低阈值 T_{low} 通过式 (11) 设置, T_{low} 分割出图像中的弱边缘, 可以在一定程度上保护不明显的边缘信息, 并减少了来自噪声的干扰。

$$T_{low} = \frac{T_{high}}{2} \quad (11)$$

如图 2 所示, 自适应 Canny 分割出的粗边缘信息, 在低噪声干扰的情况下已经达到了一定的准确度。粗边缘信息在 Neck 部分起到了重要的辅助作用。由于 Decoder 学习到的图像特征往往受限于训练数据集的质量不均, 模型在学习阶段可能忽略大量弱边缘信息, 甚至将部分关键边缘像素误判为背景。通过引入自适应 Canny 模块, 模型能够在 Decoder 学习到的特征基础上, 额外补充边缘信息, 从而进行特征对比与互补。这种机制使得模型在每个阶段生成的边缘图更加精准, 有效提升对细节信息的保留能力。

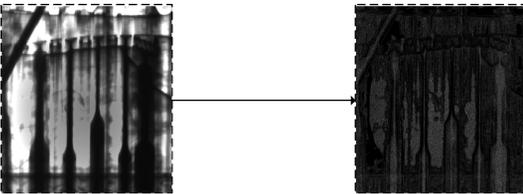


图 2 自适应 Canny 模块的分割效果
Fig. 2 Result of the adaptive Canny module

2.2 卷积块注意力模块

注意力机制作为深度学习领域近些年来最重要的成就之一, 被广泛应用于各类任务中, 人们利用它强大的信息过滤与选择能力, 开发出许多优秀的算法。卷积注意力模块^[14]CBAM 于 2018 年被提出, 这是一种应用于前馈卷积神经网络的高效而简洁的注意力模块, 当特征被输入到 CBAM 中时, 该模块会将特征沿着通道和空间两个维度向前传播, 如图 3 所示。

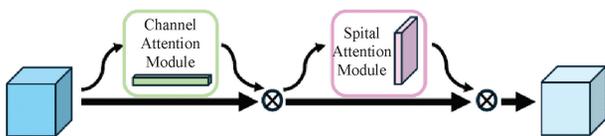


图 3 卷积块注意力模块
Fig. 3 Convolutional block attention module

当一个输入特征几位 $F \in R^{C \times H \times W}$ 进入模块后, CBAM 顺序地推断 1D 通道注意力图 $M_c^{C \times 1 \times 1}$ 和 2D 空间注意力图 $M_s \in R^{1 \times H \times W}$, 这个过程可以描述为:

$$F' = M_c(F) \otimes F \quad (12)$$

$$F'' = M_s(F') \otimes F' \quad (13)$$

其中, \otimes 代表逐元素乘法, 通道注意力模块与空间注意力模块如图 4 所示。

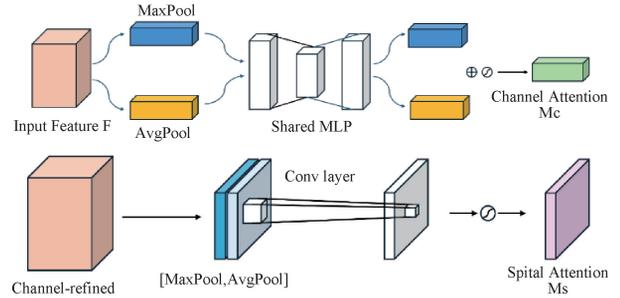


图 4 通道注意力与空间注意力模块
Fig. 4 Channel attention and spatial attention

通道注意力模块会将传入的特征分别通过最大池化和平均池化两个通道, 生成两种不同的空间特征, 用 F_{avg}^c 和 F_{max}^c 分别来表示最大池化通道与平均池化通道的特征, 接着它们被传入到共享的多层感知机中产生注意力图 $M_c \in R^{C \times 1 \times 1}$, 为了保证整体结构的轻量化, 将隐藏层大小设置为 $R^{C/r \times 1 \times 1}$, 其中 r 是缩减倍率, 通道注意力模块最终可以表述为:

$$M_c(F) = \sigma(W_1(W_0(F_{avg}^c))) + W_1(W_0(F_{max}^c))) \quad (14)$$

空间注意力模块会将传入的特征沿着轴向传播, 依次通过最大池化与平均池化, 其中两个池化操作会生成 2 个 2D 图: $F_{avg}^s \in R^{1 \times H \times W}$ 和 $F_{max}^s \in R^{1 \times H \times W}$ 。接着将输出经过卷积层生成 2D 注意力图, 空间注意力模块可以表示为:

$$M_s(F) = \sigma(f^{7 \times 7}([F_{avg}^s; F_{max}^s])) \quad (15)$$

CBAM 模块从空间与频域两个维度挖掘学习编码器与自适应 Canny 模块提供的特征, 对比学习两者的异同, 挖掘图像中容易被遗漏的边缘像素, 有效提升了模型的学习能力与抗噪声能力。

2.3 损失函数

边缘检测任务常用的交叉熵损失函数往往不能很好地在训练过程中给予模型正向引导^[15], 他们可能导致模型更关注背景, 或是噪声, 因为训练图像中这两者往往会与前景混淆^[16]。为了保证训练时模型能学习到准确的边缘信息, 衡量训练结果与目标标签之间的差距, 引入一种复合型的损失函数。

$$L_{floss} = \sum_{i=1}^3 L_1(\hat{y}_i, y) + L_2(\hat{y}_{dfuse}, y) \quad (16)$$

其中, $L_1(\hat{y}_i, y)$ 和 $L_2(\hat{y}_{dfuse}, y)$ 是加权交叉熵损失函数^[17], 一种用来衡量非边缘与边缘像素间的差距的函

数,如式(17)所示。

$$L_1 = \omega_{side} \cdot L_{side} + \omega_{fuse} L_{fuse}(P, Y) \quad (17)$$

其中, ω_{side} 和 ω_{fuse} 分别代表每个阶段单独输出的权重与最终输出的权重,函数 $L(\cdot)$ 是指交叉熵损失函数,公式为:

$$L(\hat{Y}, Y) = -\alpha \sum_{i \in Y^+} \log(1 - \hat{y}_i) - \beta \sum_{i \in Y^-} \log(\hat{y}_i) \quad (18)$$

$$Y^+ = \{i \mid y_i \in Y, y_i > \delta\} \quad (19)$$

$$Y^- = \{i \mid y_i \in Y, y_i = 0\} \quad (20)$$

其中, Y^+ 和 Y^- 分别表示边缘和非边缘像素点, α 是集合 $Y^+ \cup Y^-$ 中负样本的比例。超参数 β 用来平衡边缘与非边缘像素点的重要性, δ 是用来删除模语义上存在争议的像素点的阈值。当使用 L_1 来监控模型训练时,模型会将尽可能多的将像素点判断为边缘,这会导致许多噪声与背景被误判为边缘,使得输出不够精确。

为了解决这个问题,提出了 L_2 损失函数:

$$L_2(\hat{Y}, Y) = L_{ce} + \lambda_1 L_{bdry} + \lambda_2 L_{tex} \quad (21)$$

L_{ce} 是权重交叉熵函数(weighted cross entropy),其公式与上文提到的式(17)相同。 L_{bdry} 和 L_{tex} 是边界跟踪融合函数,其作用是可以帮助模型在训练期间对混淆像素进行边缘感知抑制,使得模型更好得分类处于边缘与非边缘之间的混淆像素,公式为:

$$L_{bdry}(\hat{Y}, Y) = - \sum_{p \in E} \log \left(\frac{\sum_{i \in L_p} \hat{y}_i}{\sum_{i \in R_p^e \setminus L_p} \hat{y}_i + \sum_{i \in L_p} \hat{y}_i} \right) \quad (22)$$

$$L_{tex}(\hat{Y}, Y) = - \sum_{P \in Y^E} \log \left(1 - \sum_{i \in R_p^t} \hat{y}_i \right) \quad (23)$$

其中, E 是所有像素点中边缘像素的集合, R_p^e 与 R_p^t 表示小的图像块(例如一个 5×5 的区域),而 R_p^e 中的边缘点几何表示为 L_p 。利用 L_{cat} 改善 L_{up} 对混淆点处理不佳的情况,使得最终的复合损失函数 L_{floss} 能够精确的引导模型学习图像中的边缘特征。

3 实验结构与分析

3.1 实验数据集准备

本文中使用的数据集由中国航发四川涡轮研究院的高能 X 射线设备所采集。如图 5 所示,由射线源产生的 X 射线穿透航空发动机的待测区域,之后投射到闪烁屏上,将 X 射线转换为可见光,在屏上形成可见光投影,最后由探测器分系统中的 CCD 相机接受可见光投影形成图像数据 600 张左右。

图 6 中展示了一些典型且质量较高的图片,可以看到,原始数据质量较低,需要对数据进行预处理才能用于后续工作。

由于采集到的数据质量存在较多重复,需要对获得的数据进行增强,减少模型过拟合的风险,首先提取出采集

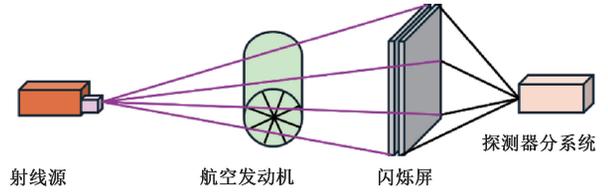


图 5 X 射线图像采集系统示意图

Fig. 5 Schematic diagram of the X-ray image acquisition system

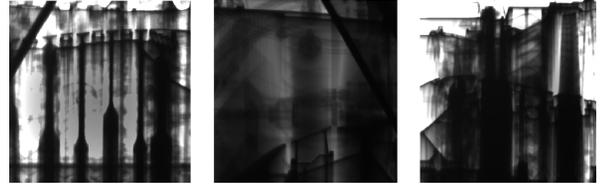


图 6 低压涡轮转子叶片高能 X 射线图像

Fig. 6 High-energy X-ray image of a rotor blade

图像中质量较高的图片 200 张作为原始数据集,如下图所示,原始图片分辨率为 $2048 \text{ pixel} \times 2048 \text{ pixel}$,直接用作训练会导致极其消耗硬件资源且训练速度缓慢,并且图上的噪声等问题会极大影响训练质量。为了解决这个问题,将原始图像分给为多个小的 patch,如图 7 所示,使用数据增强技术对图片进行随机的光照变换、旋转以及对对比度升降后,再随机裁剪到 $300 \text{ pixel} \times 300 \text{ pixel}$,这样可以对数据集进行有效扩充,并且充分得利用其中高质量的图片,降低模型的过拟合风险,最终获得了 1 200 张用于训练的图像。

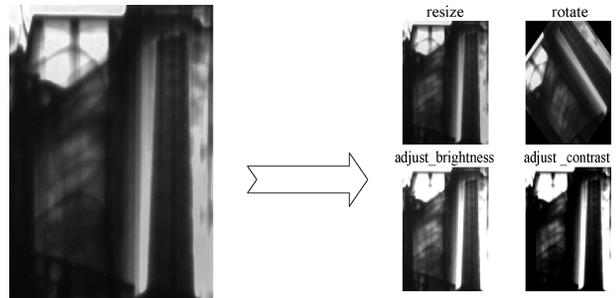


图 7 数据集增强技术

Fig. 7 Dataset enhancements

增强后的数据集按照 7 : 2 : 1 划分为训练集、验证集以及测试集,验证集用作衡量训练过程中的训练质量,测试集用作测试模型输出边缘图像的质量。

3.2 实验相关数据设置

本实验的硬件以及软件环境配置如表 1 所示,实验过程中的超参数如表 2 所示。

为了验证最终的模型分割准确率,引入最佳数据集尺度(optimal dataset scale, ODS)和最佳图像阈值(optimal image scale, OIS)^[18]这两个最常用的方法来进行评价,同时也使用均方损失误差(mean squared error, MSE)来评价模型性能。

表 1 实验环境

Table 1 Experimental environment

| 实验设备 | 类型/版本号 |
|--------------|-----------------------|
| GPU | Nvidia Geforce 3090×2 |
| 实验系统 | Windows11 |
| 开发环境 | Pycharm2023 |
| python | 3.8.20 |
| Pytorch+cuda | 2.4.1+11.6 |
| torchvision | 0.19.1 |

表 2 超参数设置

Table 2 Super parameter settings

| 参数 | 数值/类别 |
|---------|---------------------|
| 图像尺寸 | 300 pixel×300 pixel |
| 优化器 | Adam |
| 批量大小 | 8 |
| 起始学习率 | 8×10^{-4} |
| 迭代次数 | 50 |
| 学习率调整方式 | 分段式学习率衰减策略 |
| 随机种子 | 1 021 |

$$ODS = \max_{\theta} \frac{2P_{\theta}R_{\theta}}{P_{\theta} + R_{\theta}} \quad (24)$$

$$OIS = \frac{1}{N} \sum_{i=1}^N \max_{\theta_i} \frac{2P_{\theta_i}R_{\theta_i}}{P_{\theta_i} + R_{\theta_i}} \quad (25)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (26)$$

对于 ODS 来说,其中 θ 代表某个全局最优阈值, P_{θ} 和 R_{θ} 代表着该阈值下的准确率与召回率。该指标衡量得是模型在整个数据集上的表现,强调模型得整体性能。而对于 OIS 说 N 是数据集中得图像数量, i 代表当前指向得图片, θ_i 是图片 i 的最佳阈值, P_{θ_i} 和 R_{θ_i} 是图片 i 当前最佳阈值下的准确率与召回率, OIS 反映的是模型在每个图片上的表现,强调的是局部性能。而 MSE 代表着真实值与预测值之间的平方值均值,用来衡量预测精度。召回率与准确率的公式如下:

$$P = \frac{TP}{TP + FP} \quad (27)$$

$$R = \frac{TP}{TP + FN} \quad (28)$$

其中, TP 是正确检测出的边缘点数, FP 是错误检测出的边缘点数, FN 是未检测出的边缘点数。

3.3 消融实验

为了验证本模型提出的 Canny 边缘信息提示模块 (canny information assist, CIA), 与 CBAM 模块在模型中的作用, 文中使用了消融实验来进行对比, 消融实验是指通过单独激活某些模块或者全部模块来验证每个部分在

整体模型上发挥的效果, 其结果如表 3 所示。

表 3 消融实验结果

Table 3 Ablation experimental results

| Base | CIA | CBAM | fLoss | ODS | OIS | MSE | Params |
|------|-----|------|-------|-------|-------|-------|------------------|
| ✓ | | | | 0.724 | 0.753 | 0.574 | 59×10^3 |
| ✓ | ✓ | | | 0.683 | 0.715 | 0.682 | 59×10^3 |
| ✓ | | ✓ | | 0.753 | 0.786 | 0.258 | 63×10^3 |
| ✓ | ✓ | ✓ | | 0.802 | 0.814 | 0.128 | 63×10^3 |
| ✓ | ✓ | ✓ | ✓ | 0.825 | 0.831 | 0.088 | 63×10^3 |

可以看到, 只包含编码器和解码器的 BASE 模型在 ODS 上取得了 0.724, 但 OIS 上取得了 0.753 的表现, 这表明基础模型在当前数据集下表现不错, 具有一定的泛化性, 并且针对某个单独图片进行特化时也可以表现得更好, 这证明了多尺度结构在边缘分割任务下的有效性, 但 MSE 较高说明模型生成的边缘图像误差较大; 当激活 CIA 时, 在 ODS 和 OIS 上分别下降了 0.041 和 0.038, MSE 也升高了 0.108, 这表明模型受未经学习的粗边缘信息影响, 性能全面下降, 这可能时粗边缘信息中的噪声和误判像素点让模型学习到了太多无用信息; 当激活 CBAM 时, 模型在 ODS 和 OIS 上分别提升了 0.029 和 0.033, MSE 下降了 0.316, 模型相较 BASE 情况下, 有全面的提升, 无论是在整体数据集上, 还是针对某个单独图片时, 模型都展现了较强的泛化性和适应能力。而当同时激活 CIA 和 CBAM 时, ODS 和 OIS 分别提升了 0.078 和 0.061, MSE 下降了 0.446, 模型性能有了惊人的提升, 无论是在整体数据集上的表现还是单独对某个图像的适应能力上, 都有明显提升。当模型应用了提出的 fLoss 损失函数后, 模型的各项指标均达到了最优, 而相较于 BASE 模型的 Params 只提升了 6.78%, 这表明 CACNet 提出的方法使用较小的开支得到了较高的性能提升, 证明了方法的有效性。

3.4 实验结果

将训练好的模型用于测试集, 选取数据集中几个典型图片作为样本来展示最终的分割结果, 效果如图 8 所示。

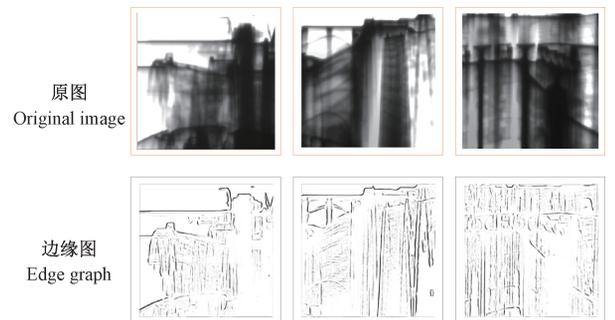


图 8 模型分割效果

Fig. 8 Model segmentation effect

可以看到,图8的原图中有许多伪影与噪声,并且存在较大的动态模糊,部分区域被阴影完全覆盖导致无法对其正常检测,这些问题对模型推理产生了较大的干扰,但图像中的多数区域 CACNet 仍旧较为清晰地对其进行了分割,可以看到主要边缘部位是十分清晰且细致地。算法目前仍旧存在一些问题,模型会将非边缘部位的一些伪像素点视作作边缘,这些像素点是 X 射线投射穿过发动机其他部位带来的叠加阴影,这是训练集本身带来的问题,由

于模型会将图片通过 CIA 模块转换成辅助信息,这些噪声会被模型错误地学习成边缘,相信更加优质的数据集可以改变这个问题。

3.5 与其他算法对比

为了更好的展现本方法对叶片边缘分割的效果,将 CACNet 的分割结果与一些经典,优秀的算法进行比较,其效果如图9与表4所示。

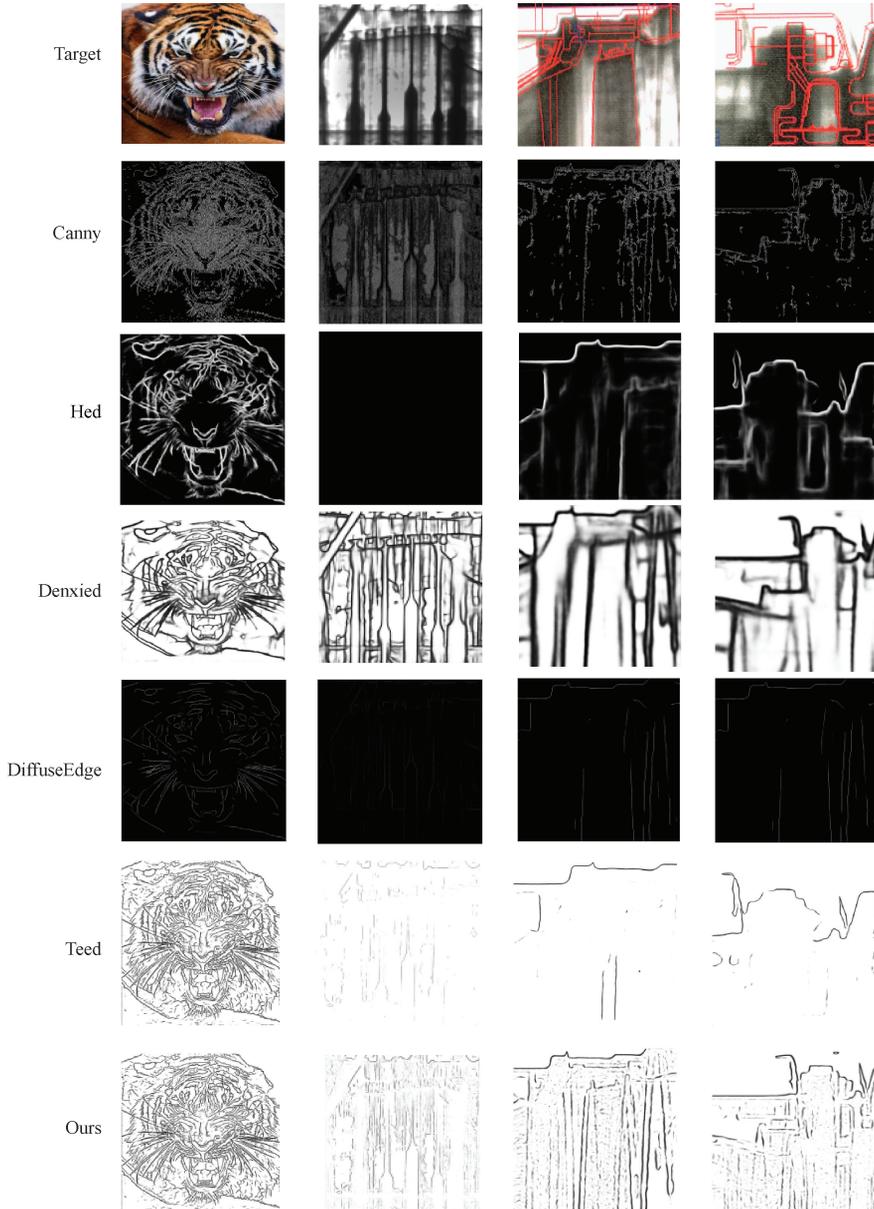


图9 不同算法分割效果对比

Fig. 9 Comparison of segmentation effects of different algorithms

上述指标中,推理时间是算法在一张 $512 \text{ pixel} \times 512 \text{ pixel}$ 图像上所消耗的时间。可以看到,传统分割算子 Canny 在普通图像(老虎和狮子)的边缘分割上表现不错,并且检测速度极快,但对于噪声较大的低压涡轮转子叶片

图像,很难将图像中的边缘进行有效分割,他们所得到的边缘图像要么是损失了大量原始信息的,要么便是大面积的误判。深度学习的算法在普通图像上表现得都非常好。但是面对叶片图像时, Hed 作为早期的分割模型,在低噪

表 4 不同算法性能对比

Table 4 Performance comparison of different algorithms

| 算法 | ODS | OIS | MSE | Params | Time/s |
|-------------|-------|-------|-------|---------------------|--------|
| Canny | 0.754 | 0.765 | 0.283 | N/A | 0.006 |
| Hed | 0.652 | 0.712 | 0.431 | 14.7×10^6 | 1.78 |
| DiffuseEdge | 0.782 | 0.791 | 0.143 | 224.9×10^6 | 34.276 |
| Denxied | 0.794 | 0.805 | 0.156 | 3.5×10^6 | 1.282 |
| Teed | 0.752 | 0.793 | 0.248 | 58×10^3 | 0718 |
| Ours | 0.825 | 0.831 | 0.101 | 63×10^3 | 1.804 |

声的图片上表现不错,但面对噪声较高的叶片图像时直接将整张图误判为背景,说明模型的鲁棒性不够好;Diffusion可以分割出最精确细致的边缘,在低噪声的情况下表现最佳,但面对图像中的复杂区域,缺少对潜藏信息的挖掘,并且推理速度较慢;Denxied推理出的图像完整且速度很快,但也存在边缘细节丢失,无法很好挖掘潜在边缘的问题。Teed的推理速度极快,但缺乏精度,无法正确的将叶片的轮廓进行还原。CACNet在对低压涡轮转子叶片边缘进行分割后所得到的分割图像,无论是在分割出的信息量,还是在边缘准确度上都要优于这些算法,在推理速度上也处在较快的行列,通过牺牲少量得资源消耗换来了精度与信息量的大幅提升。

4 结 论

针对低压涡轮转子叶片高能 X 射线图像针对图像中存在的噪声较多、动态模糊严重等问题,提出了一种边缘检测算法。本算法在特征提取阶段引入自适应 Canny 算子,为模型提供额外的辅助边缘信息,从而提升边缘学习的准确性。此外,模型采用多尺度结构,在各个阶段分别生成边缘预测图,并在末端进行融合,以获得更加细致、精确的边缘检测结果。为进一步提升模型的学习能力,设计了一种复合损失函数,以更有效地监督训练过程,从而提升整体性能。将提出的算法在转子叶片专用数据集上进行实验,结果表明,CACNet在 ODS 和 OIS 指标上分别达到 0.825 和 0.831 的优秀表现,优于传统方法和现有深度学习算法,且在保证检测精度的同时具有较快的推理速度,能够较好的在图像质量较低的情况下检测出低压涡轮转子叶片的边缘。

参考文献

[1] 崔彬彬,李鹏飞,王娟,等.航空发动机压气机转子叶尖间隙测量技术研究[J].航空精密制造技术,2024,60(6):9-12.
CUI B B, LI P F, WANG J, et al. Aero-engine compressor rotor tip clearance measurement technology research [J]. Aviation Precision Manufacturing Technology, 2024,60(6): 9-12.

[2] ANSARI M A, KURCHANIYA D, DIXIT M. A comprehensive analysis of image edge detection techniques [J]. International Journal of Multimedia and Ubiquitous Engineering, 2017, 12(11): 1-12.
[3] BERTASIUS G, SHI J, TORRESANI L. Deepedge: A multi-scale bifurcated deep network for top-down contour detection[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2015: 4380-4389.
[4] XIE S N, TU ZH W. Holistically-nested edge detection [C]. IEEE International Conference on Computer Vision, 2015: 1395-1403.
[5] SUN R, LEI T, CHEN Q, et al. Survey of image edge detection [J]. Frontiers in Signal Processing, 2022, 2: 826967.
[6] SORIA X, SAPPA A, HUMANANTE P, et al. Dense extreme inception network for edge detection[J]. Pattern Recognition, 2023, 139: 109461.
[7] JIE J, GUO Y, WU G, et al. EdgeNAT: Transformer for efficient edge detection [J]. ArXiv preprint arXiv:2408.10527, 2024.
[8] YE Y, XU K, HUANG Y, et al. Diffusionedge: Diffusion probabilistic model for crisp edge detection[C]. AAAI Conference on Artificial Intelligence, 2024, 38(7): 6675-6683.
[9] 李明,魏利胜.基于改进 Deeplabv3+的磁瓦表面缺陷分割[J].电子测量与仪器学报,2025,39(1):50-56.
LI M, WEI L SH. Segmentation of magnetic tile surface defects based on improved Deeplabv3+ [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(1): 50-56.
[10] 赵小涛,李新伟.聚焦边缘与多尺度特征的轻量化违禁品检测[J].电子测量技术,2025,48(8):165-176.
ZHAO X T, LI X W. Lightweight contraband detection focusing on edge and multi-scale features[J]. Electronic Measurement Technology, 2025, 48(8): 165-176.
[11] 王银,孙海顺,谢刚,等.基于 DeepLabV3+改进的光伏板语义分割模型研究[J].电子测量技术,2024,47(22):136-143.
WANG Y, SUN H SH, XIE G, et al. Research on improved semantic segmentation model of photovoltaic panels based on DeepLabV3+ [J]. Electronic Measurement Technology, 2024,47(22): 136-143.
[12] HENDRYCKS D, GIMPEL K. Gaussian error linear units (gelu) [J]. ArXiv preprint arXiv: 1606.08415, 2016.
[13] 孙宝民,王冬,林含潇,等.基于改进 Canny 算法的车轮踏面边缘检测[J].科技创新与应用,2024,14(31):

- 17-22,29.
- SUN B M, WANG D, LIN H X, et al. Edge detection of wheel tread based on improved Canny algorithm[J]. Scientific and Technological Innovation and Application, 2024,14(31): 17-22,29.
- [14] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]. European Conference on Computer Vision(ECCV), 2018: 3-19.
- [15] HUAN L, XUE N, ZHENG X, et al. Unmixing convolutional features for crisp edge detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 44(10): 6602-6609.
- [16] 张彪, 荀荣科, 许家忠. 基于深度学习的工业轴承缺陷检测算法研究 [J]. 仪器仪表学报, 2025, 46(4): 136-149.
- ZHANG B, XUN R K, XU J ZH. Research on industrial bearing defect detection algorithm based on deep learning [J]. Chinese Journal of Scientific Instrument, 2025,46(4): 136-149.
- [17] SHANNON C E. A mathematical theory of communication [J]. The Bell System Technical Journal, 1948, 27(3): 379-423.
- [18] LI Y, POMAB X S, XI Y, et al. A new baseline for edge detection: Make encoder-decoder great again[J]. ArXiv preprint arXiv:2409.14976, 2024.

作者简介

鲁思朋, 硕士研究生, 主要研究方向为无损检测。

E-mail: 343902993@qq.com

赵纪元(通信作者), 博士, 教授, 主要研究方向为设备状态监测与故障诊断、增材制造、无损检测。

E-mail: jiyuan.zhao@bistu.edu.cn