

基于改进YOLOv7的航空发动机叶片表面缺陷检测

张明哲, 王欣威

沈阳理工大学机械工程学院, 辽宁 沈阳

收稿日期: 2026年4月25日; 录用日期: 2026年5月18日; 发布日期: 2026年5月26日

摘要

航空发动机叶片表面缺陷类型复杂多样, 针对目前对航空发动机叶片的检测效率和精度不高的问题, 提出一种嵌入注意力机制的改进YOLOv7网络航空发动机叶片表面缺陷检测方法。通过在主干网络末尾嵌入ECA注意力机制, 增强模型对于不同特征通道之间依赖关系的学习能力。用FReLU代替SiLU作为激活函数, 提高边界框回归速率和目标定位精度。使用自制数据集对改进后的网络进行训练和测试。实验结果表明, YOLOv7-ECA网络在自制数据集上的精确率为97.9%, 召回率为96.4%, 平均精度均值为97.6%。相较于CBAM和CA注意力机制, ECA在四种缺陷的检测精度上均有一定提升。与Faster-RCNN和YOLOv5等目前的主流的目标检测模型相比, 平均检测精度分别提升1.5%和2.1%, 证明了此方法在航空发动机叶片缺陷检测中具有更高的检测精度。

关键词

航空发动机叶片, YOLOv7, 缺陷检测, ECA注意力机制, 神经网络

Aircraft Engine Blade Surface Defect Detection Based on Improved YOLOv7

Mingzhe Zhang, Xinwei Wang

School of Mechanical Engineering, Shenyang Ligong University, Shenyang Liaoning

Received: April 25, 2026; accepted: May 18, 2026; published: May 26, 2026

Abstract

Aircraft engine blade surface defects are complex and diverse. To address the current challenges of low detection efficiency and accuracy, a modified YOLOv7 network with an embedded attention mechanism is proposed for aircraft engine blade surface defect detection. By embedding the ECA

attention mechanism at the end of the backbone network, the model's ability to learn the dependencies between different feature channels is enhanced. Replacing SiLU with FReLU as the activation function improves bounding box regression rate and object localization accuracy. The improved network is trained and tested on a self-developed dataset. Experimental results show that the YOLOv7-ECA network achieves a precision of 97.9%, a recall of 96.4%, and an average precision of 97.6% on the self-developed dataset. Compared with CBAM and CA attention mechanisms, ECA improves the detection accuracy of all four defect types. Compared with current mainstream object detection models such as Faster-RCNN and YOLOv5, the average detection precision increases by 1.5% and 2.1%, respectively, demonstrating the superior detection accuracy of this method for aircraft engine blade defect detection.

Keywords

Aircraft Engine Blade, YOLOv7, Defect Detection, ECA Attention Mechanism, Neural Network

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

航空发动机是航空工业的重要基石, 涡轮叶片作为航空发动机的核心部分, 由于长时间处于高温高压环境, 叶片受金属疲劳、杂质冲击等影响, 引发裂纹、点蚀、缺口、划痕等缺陷, 甚至导致叶片失效, 引发安全事故。因此, 开发一种高效准确的叶片缺陷检测系统具有重要意义。传统的检测方法如超声、红外、涡流等在效率和准确度方面均存在不足[1]。近年来, 深度学习发展迅速, 其中 YOLO 系列算法在速度和精度上达到了平衡, 在多个公开数据集上表现优异。

目前的深度学习目标检测网络大致分为两类, 即二阶段网络和一阶段网络。二阶段网络包括两个步骤: 候选区域生成和分类识别, 是由两个网络分别完成, 代表性算法包括 RCNN、Fast RCNN 和 Faster RCNN [2]。而一阶段网络将定位与分类交给一个网络, 大大提升了推理速度, 简化了训练步骤, 代表算法包括 YOLO、SSD 等。

王栋欢[3]等基于 YOLOv4 模型提出了双主干特征融合的缺陷检测算法; 针对 6 种缺陷训练, 结果优于 YOLOv4 模型。张静[4]等优化 FasterRCNN, 搭建了细粒级的多尺度残差模 Res2S-Net-50。采用多次余弦退火衰减法调整学习率。步斌[5]等改进了 CenterNet 算法, 采用轻量级的 EPSANet 作为主干网络, 融合 PSA 分割注意力机制, 并引入了特征金字塔结构(FPN)。Ataç [6]等通过将切片辅助超推理(SAHI)算法与 Mask R-CNN 等多种算法协同使用, 有效提高了图像中小尺寸缺陷的检测率。

以上的研究在部分缺陷上取得了进步, 但对小样本如气孔、划痕等的检测效果尚不理想。本文采用 YOLOv7 网络为基础模型进行改进, 引入 ECA 注意力机制, 使用 FReLU 代替 SiLU 作为损失函数。实验结果表明本文的方法在速度和精度上均取得较大提升。

2. 优化方案

2.1. YOLOv7 结构概述

YOLOv7 的网络结构由输入层(Input)、主干(Backbone)和头部(Head)三部分组成, 如图 1 所示。输入(Input)为数据输入过程, 数据集图片经过预处理, 统一调整到目标检测模型所需的尺寸。主干(Backbone)

用于特征提取, 主要由卷积、E-ELAN 模块、MPCConv 模块以及 SPPCSPC 模块构建而成[7]。卷积层进行卷积、批量归一化和 SiLU 激活。E-ELAN 模块用来提取多维度的特征, 实现更丰富的特征学习。MPCConv 模块将特征层的感受野扩张再与普通卷积处理后的特征信息进行融合, 提高了网络的泛化性。头部(Head)是分类器与回归器, 负责将检测器输出的特征图转化为预测框。

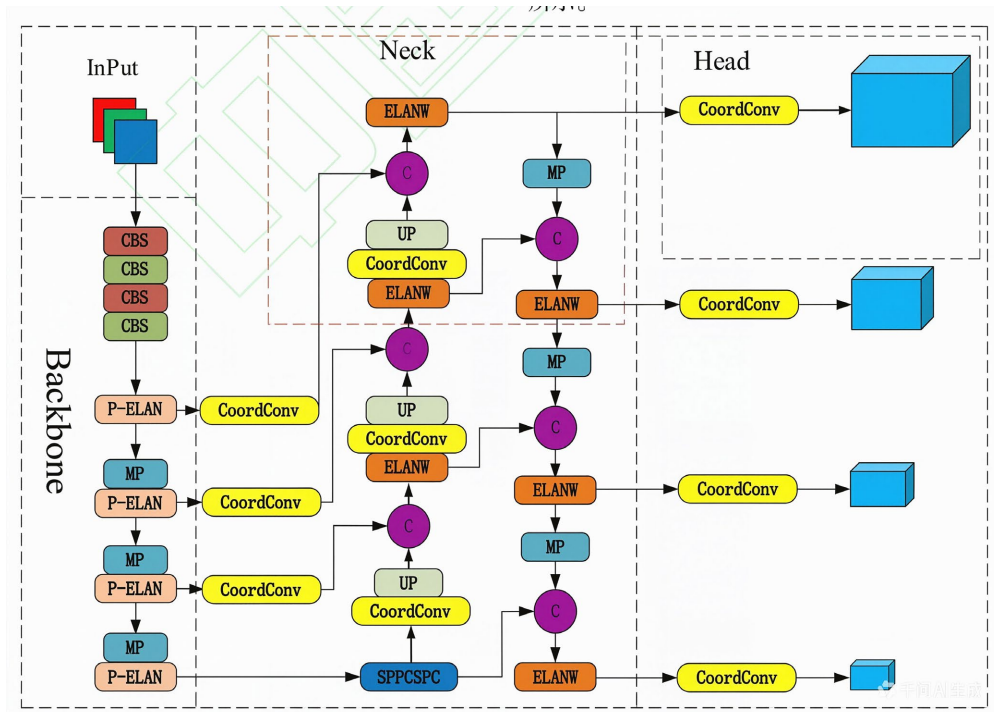


Figure 1. Network structure of YOLOv7
图 1. YOLOv7 网络结构

2.2. 激活函数优化

神经网络的基本构建模块本质上是线性变换, 而激活函数通过引入非线性, 使得网络能够学习和表达更复杂、更丰富的数据特征。YOLOv7 采用 SiLU (sigmoid)为激活函数, SiLU 激活函数的输出平滑, 映射在(0, 1)之间, 单调连续, 求导容易。且 SiLU 相较于 ReLU 解决了神经元死亡的问题。但由于其软饱和的性质, 且其输出以 0 为中心, 有负值, 计算成本较大, 反向传播时求导涉及除法, 很容易出现梯度消失, 导致训练出现问题。式(1)为 SILU 的表达式

$$SILU(X) = x \cdot \sigma(x) \tag{1}$$

航空发动机叶片表面的缺陷结构复杂、微小且空间形态不规则, 并带有纹理特征。传统 SiLU 激活函数仅对特征图进行逐通道数值变换, 仅关注通道维度特征, 忽略像素间空间位置关系、局部结构与纹理信息, 难以精准捕捉叶片裂纹、凹坑、划痕等细小缺陷的空间特征。而 FReLU 是面向视觉任务设计的空间感知型激活函数, 通过引入可学习的空间条件变换, 实现像素级自适应激活, 能够有效建模叶片缺陷的局部空间结构与几何形态。同时, FReLU 可自适应调整正负特征响应比重, 更好适配叶片复杂纹理与噪声干扰, 并以轻量化卷积结构获得强大视觉布局建模能力, 计算开销极小。因此, 本文采用 FReLU 替代 SiLU, 以提升网络对发动机叶片微小缺陷、空间边缘、局部纹理的特征提取与检测精度。式(2) (3)为 FReLU 的表达式。

$$f(x_{c,i,j}) = \max(x_{c,i,j}, T(x_{c,i,j})) \tag{2}$$

$$T(x_{c,i,j}) = x_{c,i,j}^{\omega} \cdot P_C^{\omega} \tag{3}$$

式中 T 为二维空间条件, $x_{c,i,j}$ 表示第 c 个通道上, 以 2D 位置 (i, j) 为中心的窗口, P_C^{ω} 表示此窗口在同一通道中共享的参数。

2.3. 引入 ECA 注意力机制

YOLOv7 难以兼顾多尺度目标。本文在主干网络末尾嵌入 ECA 注意力机制, 使网络对不同尺度目标的检测率均有提升。ECA 模块使用简单一维卷积操作, 保留了原始通道特征, 只增加很小的计算开销, 且 ECA 模块能够自适应地调整一维卷积核大小, 灵活地捕捉不同范围内的通道依赖性。ECA 注意力机制过程如下:

- ① 自适应平均池化(AdaptiveAvgPool2d): 将输入特征图压缩到 1×1 的大小, 得到通道描述。
- ② 一维卷积层(Conv1d): 使用 `kernel_size` 为 3 的一维卷积核, 在通道维度上进行运算。`padding` 设置为 $(\text{kernel_size} - 1)/2$, 确保卷积后的输出与输入尺寸相匹配。
- ③ sigmoid 激活函数将卷积结果映射到 0~1 之间作为注意力权重。
- ④ 特征重加权将计算得到的注意力权重作用于原特征图, 从而调整各通道的重要性。ECA 注意力机制结构如图 2 所示。




Figure 2. Structure of ECA attention mechanism

图 2. ECA 注意力机制结构

YOLOv7 基础模型在同时面临大尺度目标和小尺度目标时难以兼顾。如图所示, 在 YOLOv7 的主干网络末尾嵌入 ECA 注意力机制。对不同尺度目标的检测均有提升, 有效解决了面临多尺度目标时的困难, 且由于 ECA 机制只有一个一维通道, 增加的计算量很小。图 3 为 ECA 注意力机制嵌入位置。




Figure 3. ECA attention mechanism embedded in backbone network

图 3. ECA 注意力机制嵌入主干网络

3. 实验设计

3.1. 数据集制作

本数据集以气孔、斑块、划痕、裂缝这四种叶片典型缺陷构建自制数据集。通过工业相机在标准光照条件下采集, 覆盖不同材质、表面状态及拍摄角度的工件样本。每类缺陷均采集不少于 500 张原始图像(图 4)。




Figure 4. Dataset acquisition platform
图 4. 工业相机采集平台

采集数据后, 通过旋转、平移、缩放等方法扩充数据集数量, 对数据进行筛选, 排除不清晰、不完整的图像, 得到 800 张图像, 四种缺陷类型各 200 张。按 7:2:1 的划分为训练集、测试集和验证集。部分样本如图 5 所示。




Figure 5. Partial samples of the self-built dataset
图 5. 自制数据集部分样本

3.2. 实验参数配置

本文实验在 window11 系统下进行, GPU 为 Nvidia GeForce RTX 3060Ti, 深度学习环境为 Anaconda3、Python-3.10.13。图像输入大小为 640×640 , 初始学习率为 0.01, 迭代次数为 300, 批次为 16。评估指标包括精确率(R)、召回率(P)、F1 值以及平均精度均值(mAP)。

4. 结果分析

4.1. 改进模型训练结果

训练过程中的 mAp 如图 6 所示。最终训练模型的精确率为 97.9%, 召回率为 96.4%, mAP50 为 97.6%。图 7 是训练过程中的 PR 曲线, 可以看出不同缺陷的曲线下面积都接近于 1, 说明该模型对各类缺陷均有

较好识别效果。

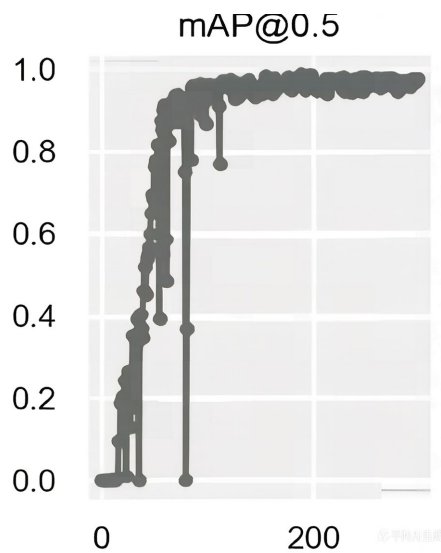


Figure 6. Average precision curve
图 6. 平均精度曲线




Figure 7. PR curve
图 7. PR 曲线

4.2. 消融实验

与当前主流的注意力机制对比进行消融试验。结果如表 1 和表 2。可见 YOLOv7-ECA 在各项指标上

均优于 YOLOv7 和添加其他注意力版本的网络, 推理时间与 YOLOv7 相比仅增加了 1 ms。

Table 1. Defect parameters

表 1. 缺陷参数

网络	裂缝/%	斑块/%	气孔/%	划痕/%	准确度/%
YOLOv7	96.1	95.3	94.2	96.2	96.1
YOLOv7 + CBAM	96.6	96.5	95.4	97.1	96.6
YOLOv7 + CA	96.9	97.9	96.9	97.5	96.0
YOLOv7 + ECA	99.6	99.5	97.6	98.9	97.9

Table 2. Training parameters

表 2. 训练参数

网络	召回率/%	F1/%	平均精度均值/%	每帧推理时间
YOLOv7	94.3	94	95.2	9.6 ms
YOLOv7 + CBAM	94.8	95	95.9	10.8 ms
YOLOv7 + CA	95.0	95	96.5	12.1 ms
YOLOv7 + ECA	96.4	98	97.6	10.9 ms

4.3. 与主流网络对比

为进一步验证本文方法的性能, 将本文方法与 YOLOv5、Faster-RCNN 进行对比实验, 表 3 为本文方法与主流网络参数对比。与 Faster-RCNN 相比, 本文方法在平均精度均值上领先 1.4%, 帧数领先 64 帧。与 YOLOv5 相比平均精度均值上领先 0.5%, 帧数提升 4 帧。

Table 3. Comparison with mainstream networks

表 3. 与主流网络对比

网络	精确率/%	召回率/%	F1	平均精度均值/%	FPS
Faster-RCNN	95.8	95.1	95	96.2	26
YOLOv5	96.2	95.4	95	97.1	86
YOLOv7-ECA	97.9	96.4	98	97.6	90

4.4. 结果可视化

使用 YOLOv7-ECA 模型对航空发动机叶片缺陷图像进行检测, 部分结果如图 8 所示。对 one (裂缝); two (斑块); three (气孔); four (划痕)四类缺陷均达到 90%以上的检测率。






Figure 8. Partial detection results
图 8. 部分检测结果

5. 结论

由于目前航空发动机叶片缺陷检测面临的精度差,效率低的问题,本文提出了一种基于改进 YOLOv7 的 YOLOv7-ECA 目标检测网络。主要改进为引入 ECA 注意力机制和 FReLU 激活函数,有效提升了模型对小尺寸、多类型缺陷的检测能力。实验结果表明, YOLOv7-ECA 在精度和速度上均优于当前主流目标检测模型,具有较高实用价值。

参考文献

- [1] 黄松岭, 彭丽莎, 孙洪宇, 等. 航空发动机叶片缺陷无损检测与在线监测技术综述[J]. 测控技术, 2023, 42(5): 1-11.
- [2] 王坤, 邵崇洲. Focus Meta R-CNN: 水下垃圾小样本目标检测算法[J]. 计算机工程与用, 2025, 61(18): 231-240. <https://link.cnki.net/urlid/11.2127.TP.20240626.1402.004>, 2025-09-01.
- [3] 王栋欢, 肖洪, 吴丁毅. 基于深度学习的航空发动机涡轮叶片自动射线检测技术研究[J]. 推进技术, 2024, 45(5): 222-230.
- [4] 张静, 农昌瑞, 张海兵, 等. 基于深度学习的发动机叶片故障检测技术[J]. 航空发动机, 2022, 48(1): 68-75.
- [5] 步斌, 张梦怡, 王超, 等. 融合多尺度及注意力机制的表面缺陷检测算法[J]. 空间控制技术与用, 2023, 49(6): 94-103.
- [6] Ataç, H.O., Kayabaşı, A. and Aslan, M.F. (2024) The Study on Multi-Defect Detection for Leather Using Object Detection Techniques. *Collagen and Leather*, 6, Article No. 37. <https://doi.org/10.1186/s42825-024-00186-2>
- [7] 孙喆, 张静, 李建兴, 等. 基于轻量化 YOLOv7-DenseBlock 的绝缘子检测算法[J]. 电网与清洁能源, 2025, 41(5): 68-74.