

新能源汽车空调膨胀阀钎焊缺陷检测系统设计

王奎龙¹ 尚雅层¹ 常 宏²

WANG Kuilong SHANG Yaceng CHANG Hong

摘 要

针对当前新能源汽车空调膨胀阀钎焊后缺陷主要依赖人工检测,存在成本高、效率低、精度差等问题,文章提出一种基于 YOLOv11 改进的表面缺陷检测算法,通过引入 RAFFConv 模块增强对缺陷区域的聚焦能力,抑制噪声干扰,提高检测精度;改进检测头结构,集成四头 ASFF 模块,自适应分配不同特征尺度权重,提升小目标缺陷检测能力;加入 SimSPPF 模块,实现多尺度特征提取与融合,提升模型对不同尺度大小缺陷的识别能力。改进算法相比原始模型召回率提升 2.4%,准确率提升 2%,mAP@50 提升 4.6%。

关键词

YOLO11n; 缺陷检测; RAFFConv; ASFF

doi: 10.3969/j.issn.1672-9528.2026.03.040

0 引言

随着新能源汽车工业的快速发展^[1],其中钎焊技术广泛应用于新能源汽车的各个关键部件。空调膨胀阀是空调系统中制冷剂流量控制的关键部件,其作用是将高压液态制冷剂节流降压,使其变为低压低温的气液混合物,并送入蒸发器吸热,从而达到制冷效果。目前其钎焊后的缺陷检测主要由人工进行完成,存在着检测成本高、效率低、稳定性差、精度低等问题。钎焊过程中易出现缺陷如:气泡、裂纹、钎料

铺展不均匀、局部的凹陷或隆起。近年来,采用机器视觉代替人工对物体表面缺陷的检测有较多应用。

冷岳峰等^[2]针对钢材表面缺陷检测中漏检以及对于细小缺陷检测精度不佳等问题,提出了一种改进 Faster R-CNN 算法。在 FPN 与 RPN 之间引入特征融合模块与轻量化通道注意力模块,增加模型对精细特征的捕捉能力。车璇等^[3]提出一种基于 RetinaNet 的目标检测优化算法,主要使用白酒瓶盖瑕疵数据集进行检测,方法是将网络 Backbone 替换为 SwinTransformer,其包含的窗口注意力机制运算有效提升瓶盖瑕疵检测精度同时降低复杂度节省了计算量。Lee 等^[4]使用 CNN 网络模型识别铜管和不锈钢之间的钎焊过程中的接

1. 西安工业大学机电工程学院 陕西西安 710021
2. 西安北辰亿科电子科技有限公司 陕西西安 710399

- itations-of-handsfree-acoustic-echo-cancellers-Birkett-Goubran/16898cb21e72a11011794c829234e6bf220dad60.
- [6] NIEMISTO R, MAKELA T, MYLLYLA V. Robust fast affine projection algorithm for nonlinear acoustic echo cancellation[C]//2002 11th European Signal Processing Conference. Piscataway: IEEE, 2012[2026-01-22]. <https://ieeexplore.ieee.org/document/7072029>.
- [7] COMMINIELLO D, SCARPINITI M, AZPICUETA-RUIZ L A, et al. Nonlinear acoustic echo cancellation based on sparse functional link representations[J]. IEEE/ACM transactions on audio speech & language processing, 2014, 22(7): 1172-1183.
- [8] VAERENBERGH S V, AZPICUETA-RUIZ L A. Kernel-based identification of hammerstein systems for nonlinear acoustic echo-cancellation[C]//2014 IEEE International Conference on

Acoustics, Speech and Signal Processing (ICASSP). Piscataway: IEEE, 2014: 3739-3743.

- [9] XIAO L S, WU M, YANG J. A new efficient filtered-x affine projection sign algorithm for active control of impulsive noise[J]. Signal processing, 2016, 120: 456-461.
- [10] HIRANO G, SHIMAMURA T. A modified IPNLMS algorithm using system sparseness[C]//2012 International Symposium on Intelligent Signal Processing and Communications Systems. Piscataway: IEEE, 2012: 876-879.

【作者简介】

杨瑞丽(1991—),女,河南商丘人,硕士研究生,讲师,研究方向:物联网、自适应滤波算法。

(收稿日期: 2025-08-24 修回日期: 2026-03-04)

注意力机制作为深度学习中的关键技术，能够引导模型聚焦于重要特征，提高网络性能。现有的空间注意力算法（如 CBAM 和 CA）仅关注空间特征，无法完全解决卷积核参数共享的问题。RFAConv 兼顾空间感受野特征的提取，并通过注意力机制动态调整大卷积核的权重，提升了模型的表达灵活性和感知能力。RFAConv 采用接收场注意卷积（RFA），作为标准卷积的替代方法，在几乎不增加计算成本和参数的情况下，显著提升网络性能^[10]，使其在钎焊缺陷检测任务中具有更高的精度和泛化能力。如图 2 所示。




图 2 RFAConv 整体结构

RFAConv 模块引入的 RFA 机制使得网络能够为每个感受野分配独立的权重，从而实现基于区域特征的动态卷积参数调整。该机制有效打破了传统卷积中参数共享的限制。其计算公式为：

$$F = \text{Softmax}\left(g^{1d}\left(\text{AvgPool}(X)\right)\right) \times \text{ReLU}\left(\text{Norm}\left(g^{k \times k}(X)\right)\right) = A_{rf} \times F_{rf} \quad (3)$$

由式（3）可知，RFA 的计算过程包括以下几个关键步骤。

首先，通过输入特征图 X 通过 $k \times k$ 的卷积操作 $g_{(k \times k)}(X)$ 进行特征提取捕捉局部特征。特征图 X 经过平均池化操作 $\text{AvgPool}(X)$ 提取更全局的特征统计信息，有助于压缩空间维度并减少计算复杂性，然后使用 1×1 的分组卷积交互信息。

后对 $g_{(k \times k)}(X)$ 的结果应用规范化和 ReLU 激活函数，增强非线性特性并进行特征标准化处理。再然后利用 Softmax 函数处理平均池化后的结果生成注意力图 A_{rf} 。通过 Softmax 函数使得不同位置的权重可以进行归一化，以突出更重要的特征。最后，将 Softmax 生成的注意力 A_{rf} 与 $g_{(k \times k)}(X)$ 经过 ReLU 和 Norm 处理后的感受野空间特征图 F_{rf} 进行元素乘法操作，最终生成 $A_{rf} \times F_{rf}$ 。这一步通过动态调整每个通道的权重，以加强模型对关键信息的捕捉能力。为增强模型的特征表达能力，本文在 YOLOv11 的主干网络中将四个卷积层替换，从而提升模型对输入特征的适应性，尤其在复杂背景下的小目标钎焊缺陷检测中表现出更高的准确性。

2.3 改进检测头 Detect_ASFF

目标检测任务中，为提高对多尺度目标的检测性能，常利用特征金字塔网络（FPN）对不同层级的特征信息进行有效整合。然而，传统的融合方法（如 FPN 中的加权相加或拼接）

存在信息损失或不均衡的问题。ASFF 模块通过自适应学习不同尺度特征的权重，让网络自动选择最优的特征融合方式，进而提高检测效果^[11]。

ASFF 模块在钎焊缺陷检测中具有显著优势，能够自适应融合不同尺度的特征，提高检测精度并增强鲁棒性。钎焊缺陷（如气孔、裂纹、未熔合等）尺寸、形态和分布各异，传统的特征金字塔（FPN）难以高效整合这些信息，而 ASFF 通过自适应分配不同尺度特征的权重，确保最优的特征融合，从而提高小目标缺陷的检出率，同时增强深层特征在目标检测中的贡献，提升缺陷定位的精准度。此外，钎焊区域往往存在复杂的纹理背景，受光照、焊接角度和材料反光等因素影响，易导致误检。ASFF 通过优化不同层次特征的融合，增强真正缺陷区域的特征表达，减少背景干扰，并降低不同尺度特征之间的不均衡影响，使网络聚焦于最有效的信息，提升检测的稳定性。

本文通过引入 ASFF 模块来对检测头进行改进，可用于优化检测头的多尺度特征融合，提升小目标缺陷的检测能力从而提高网络的特征融合能力，同时引入四头版本，原网络基础上增加了一个特征图尺寸为 $160 \text{ px} \times 160 \text{ px}$ 的小目标检测头进一步提高模型对于小目标钎焊缺陷的检测能力。如图 3 所示。




图 3 Detect_ASFF 模块

2.4 引入 SimSPPF 模块

空间金字塔池化（spatial pyramid pooling, SPP）主要是为了解决输入图像尺寸不固定的问题。在传统的卷积神经网络中，通常要求输入图像具有固定的尺寸，这在实际应用中会带来较多不便。而空间金字塔池化能够对不同尺寸的输入图像产生固定长度的输出，使得网络可以接受任意尺寸的图像输入。

YOLOv11 中使用的 SPPF 是将 SPP 中并行连接的池化操作改为串行连接，在保持性能不变的情况下，提高了运算效率。本文引入的 SimSPPF 是将 SPPF 中 CBS 模块的激活函数 SiLU 替换成函数形式更简单的 ReLU 而得，效率更为高效。SimSPPF 模块结构如图 4 所示。其中 SimConv 是一个自定义的卷积模块，包含卷积操作、拟归一化和 ReLU 激活函数，它的作用是对输入特征图进行卷积操作以提取特征，并通过批归一化来加速训练过程和提高模型的稳定性，ReLU 激活函数则引入非线性，增强模型的表达能力。该模块首先进行卷积模块操作对输入特征图进行压缩，然后经过 3 个相同的

MaxPool2D 池化，以串联叠加的方式从中得到不同感受野信息的特征图，然后将 4 个维度的特征图进行 Concat 融合，最后再经过一个 SimConv 卷积层将融合后的特征图转化为指定的输出通道数。




图 4 SimSPPF 模块结构

通过以上设计，SimSPPF 模块能够有效地提取多尺度特征，并融合这些特征以增强模型对不同大小的钎焊缺陷识别能力。同时，简化的设计使得计算效率更高，适用于对实时性要求较高的钎焊缺陷检测系统。

2.5 评估指标

为全面衡量检测模型的效果，实验采用精确率（Precision）、召回率（Recall）及平均精度均值（mAP）三项指标进行评估，其计算公式为：

$$P = \frac{TP}{TP+FP}$$
(4)

$$R = \frac{TP}{TP+FN}$$
(5)

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i$$
(6)

式中：TP（true positive）表示被正确检测的目标数量；FP（false positive）表示模型将非目标样本误判为目标的数量；FN（false negative）表示实际为目标但未被检测出的样本数量；N 表示类别的总数；AP_i 表示第 i 个类别的平均精度。

3 实验和结果分析

3.1 实验准备

实验平台具体配置如下：CPU 为 Intel(R) Core(TM) 17-14700、搭载 NVIDIA GeForce RTX 5080 显卡。软件环境方面，模型基于 PyTorch 1.8.1 框架开发，运行于 Python 3.8 环境，CUDA 版本为 11.1。模型训练参数：训练轮次 epochs 为 300 轮，图像大小 imsz 为 640，批次 batch 为 32，工作线程 works 为 8，初始学习率 lr0 为 0.01。

3.2 数据集

本文使用自制的工厂新能源汽车空调膨胀阀钎焊缺陷数据集对算法性能进行评估。通过数据增强提升模型的鲁棒性，最终生成了 1 948 张钎焊缺陷图片，其中训练集包含 1458 张

图片，验证集包含 490 张图片。根据实际工件钎焊缺陷的特征，缺陷类型被归纳为四个类别：“LackSoldering”（缺焊）：钎料仅填充一侧，未形成圆角；“FlowSoldering”（流焊）：钎料流到非钎焊区域或发生滴落；“Overburning”（过烧）：焊接温度过高导致工件内外表面氧化严重，并出现脱落；“Divulge”（泄漏）：工件出现细小孔洞，导致泄漏现象。具体标签数量分布如下：LackSoldering 为 1 244 个、FlowSoldering 为 679 个、Overburning 为 362 个、Divulge 为 268 个。

本数据集充分考虑了钎焊缺陷在实际工业场景中的复杂性与多样性，能够有效评估目标检测算法在缺陷识别任务中的性能。如图 5 所示。



图 5 数据集示例

3.3 消融实验

为了更直观地表现出本研究对 YOLOv11 每个改进的提升效果，使用相同数据集、参数和环境条件分别通过引入注意力卷积模块 RFACnv、SimSPPF 模块、改进检测头 Detect_ASFF 进行消融实验，消融实验结果如表 1 消融实验所示。

表 1 消融实验

	RFACnv	SimSPPF	Detect_ASFF	P/%	R/%	mAP@0.5
1				77.2	80.3	0.787
2	√			80.0	78.6	0.823
3		√		77.1	79.8	0.794
4			√	76.6	78.7	0.802
5	√	√		79.0	81.6	0.821
6	√		√	77.8	81.8	0.828
7		√	√	77.6	80.8	0.792
8	√	√	√	79.6	82.3	0.833

表 1 中的实验 2~8 用于评估各类改进方法对 YOLO11n 性能的影响，实验 1 展示了原始 YOLO11n 在自建数据集上的训练结果。实验 2 通过加入 RFACnv 模块，准确率和

mAP@0.5 分别提高 2.8% 和 3.6%；实验 3 通过更改池化层为 SimSPPF，mAP@0.5 提高 0.7%；实验 4 为引入四头版本 Detect_ASFF 检测头，mAP@0.5 提高 1.5%。三组实验表明，三处改进均对原始网络的 mAP@50 具有提高作用。实验 5~7 将多个模块组合融入 YOLO11n 可以看出，更换 RFACnv、更换 SimSPPF、引入四头版本 Detect_ASFF 检测头的任意两种组合，mAP@50、召回率、精确率均有不同情况的提升。实验 8 为将 3 个改进点同时融入，可以发现指标均有明显提升，召回率提升 2%、准确率提升 2.4%、mAP@50 提升 4.6%。

综上所述，实验结果充分验证了各项改进措施在提升 YOLO11n 对新能源汽车空调膨胀阀钎焊缺陷检测性能方面的有效性，提高钎焊缺陷检测的精度，达到实验目的。

3.4 对比实验

本文选取了当前主流的目标检测算法 Faster R-CNN、YOLOv8 以及 YOLOv11 进行对比实验，相关实验结果汇总如表 2 所示。

表 2 对比实验

算法模型	P/%	R/%	mAP@0.5
YOLOv8	78.0	79.9	0.798
YOLOv11	77.2	80.3	0.787
Faster R-CNN	72.8	75.3	0.775
改进算法	79.6	82.3	0.833

改进算法的准确率（79.6%）和召回率（82.3%）均高于 YOLOv8、YOLOv11 和 Faster R-CNN，说明它在减少误检的同时还能有效提升目标检出率。同时，其 mAP@0.5 达到 0.833，相比 YOLOv8（0.798）和 YOLOv11（0.787）提升明显，表明其在不同类别上的检测性能更优，整体检测能力更强。综合来看，改进算法在精度、召回率和整体检测性能方面均取得了显著提升，能够有效减少误检和漏检，适用于对检测精度要求较高的场景，使其在实际应用中更具优势。

4 结论

本研究完成了新能源汽车空调膨胀阀钎焊检测系统的搭建。首先根据待检测工件和缺陷的大小对视觉系统平台搭建。其次基于 YOLO11n 提出了一种钎焊缺陷检测算法，通过采用 RFACnv 替代原有的四个卷积模块，增强了模型的特征表达能力，使其在面对复杂且难以检测的钎焊缺陷小目标时，能够更准确地提取和表达关键信息。同时引入 ASFF 模块来对检测头进行改进和加入 SimSPPF 模块，进一步提高模型对于小目标钎焊缺陷的检测能力。

实验结果表明，相比于 YOLOv11n 算法，改进后的模型在各项性能指标上均有提升。召回率提高 2.4%，准确率提高

2.0%，mAP@50 提升 4.6%，并且与其他现阶段主流目标检测算法也具有优势，具有一定的工程应用价值。

参考文献：

- [1] 李成鑫. 我国新能源汽车保有现状及发展趋势分析[J]. 汽车实用技术, 2024, 49(4):8-12.
- [2] 冷岳峰, 刘正, 徐宝祯, 等. 改进 Faster R-CNN 的钢材表面缺陷检测[J]. 机械科学与技术, 2025, 44 (1):75-83.
- [3] 车璇, 朱文忠, 李韬, 等. 基于改进 RetinaNet 的白酒瓶盖缺陷检测方法[J]. 国外电子测量技术, 2023, 42(4):173-180.
- [4] LEE C W, WOO S, KIM J. A Study on defect detection of dissimilar joints in cu-STS tubes using infrared thermal imaging of induction heating brazing[J]. Processes, 2024, 12(1): 163.
- [5] HSIEH C C, LIN Y W, TSAI L H, et al. Offline deep-learning-based defective track fastener detection and inspection system[J]. Sensors and materials, 2020, 32(10):3429.
- [6] 朱磊, 王倩倩, 姚丽娜, 等. 改进 YOLOv5 的织物缺陷检测方法[J]. 计算机工程与应用, 2024, 60(20):302-311.
- [7] LIU Y H, ZHENG Y Q, SHAO Z F, et al. Defect detection of the surface of wind turbine blades combining attention mechanism[J]. Advanced engineering informatics, 2024, 59: 102292.
- [8] BAILLY A, BLANC C, FRANCIS É, et al. Effects of dataset size and interactions on the prediction performance of logistic regression and deep learning models[J]. Computer methods and programs in biomedicine, 2022, 213: 106504.
- [9] KHANAM R, HUSSAIN M. YOLOv11: an overview of the key architectural enhancements[EB/OL]. (2024-10-23)[2026-01-22]. <https://doi.org/10.48550/arXiv.2410.17725>.
- [10] ZHANG X, LIU C, YANG D G, et al. RFACnv: innovating spatial attention and standard convolutional operation[EB/OL]. (2024-03-28)[2026-01-22]. <https://doi.org/10.48550/arXiv.2304.03198>.
- [11] LIU S T, HUANG D, WANG Y H. Learning spatial fusion for single-shot object detection[EB/OL]. (2019-11-25)[2026-01-22]. <https://doi.org/10.48550/arXiv.1911.09516>.

【作者简介】

王奎龙（2000—），男，安徽阜阳人，硕士，研究方向：计算机视觉。

尚雅层（1966—），女，陕西西安人，硕士，教授、硕士生导师，研究方向：计算机数字控制、自动控制理论。

（收稿日期：2025-07-28 修回日期：2026-03-03）