

# 深度学习下电子元件多维缺陷检测方法

高帅帅

陕西国际商贸学院，陕西西安，712046；

**摘要：**随着电子技术的快速发展与智能制造的深入推进，电子元件的复杂程度与集成度呈现出指数级增长态势，对其质量检测提出了更为严格与精细化的技术要求。电子元件作为现代电子系统的核心组成部分其质量缺陷不仅直接影响产品的整体性能与可靠性更可能引发系统性故障，导致重大经济损失与安全隐患。传统的人工检测方法虽然在某些特定场景下仍有应用，但普遍存在主观性强，检测效率低下，人力成本高昂与一致性差等固有缺陷已难以适应现代高精度与大批量的工业生产需求。基于传统机器视觉技术的自动检测方法在处理复杂背景干扰，微小尺寸缺陷识别以及多种缺陷类型同时检测等关键技术挑战时表现不佳，检测精度与鲁棒性有待提升。近年来，深度学习技术在计算机视觉与图像识别领域取得了革命性突破为电子元件缺陷检测提供了全新的技术解决思路与发展方向。深度学习模型具备自动学习复杂图像特征的能力，拥有强大的多层次特征提取与模式识别能力在复杂工业场景下展现出卓越的检测性能。因此，深入研究基于深度学习的电子元件多维缺陷检测方法对于推动智能制造技术进步具有重要的理论意义与广阔的实用价值。

**关键词：**深度学习；电子元件；缺陷检测；卷积神经网络；多维特征；质量控制

**DOI：**10.69979/3041-0673.26.01.105

## 引言

电子元件在现代工业生产中地位日益重要，其质量直接影响整个电子系统的可靠性与安全性。传统的缺陷检测方法存在检测精度低，效率不高与无法处理复杂多维特征等问题。为解决这些问题提出一种基于深度学习的电子元件多维缺陷检测方法。该方法采用改进的卷积神经网络架构，结合多尺度特征融合与注意力机制，实现对电子元件表面裂纹，焊接缺陷与尺寸偏差等多种缺陷的精确识别。通过构建包含6类典型缺陷的数据集进行验证，实验结果表明，所提方法在检测准确率，召回率与F1值方面均优于传统方法其中检测准确率达到98.7%，相比传统方法提升4.2%，检测时间缩短至0.15秒为电子元件质量控制提供了有效的技术支撑。

## 1 电子元件多维缺陷检测关键技术

### 1.1 电子元件缺陷特征与检测挑战

电子元件制造过程中产生的缺陷呈现显著的多维度复杂特征<sup>[1]</sup>表面裂纹缺陷长度范围在0.1-5mm之间，宽度仅为1-10 $\mu$ m呈现高长宽比的线性特征。焊点虚焊缺陷表现为球形度偏差与接触面积不足涉及三维形貌重构。引脚弯曲角度偏差通常在2-15°范围内需要精确的几何测量算法。这些缺陷在成像过程中受到材料反射特性，光照条件与成像角度的影响，产生灰度不均匀分布与边缘模糊现象传统基于单一特征描述子的检测算法难以同时捕获纹理，形状与几何等多维信息在复杂背

景与多种缺陷并存的场景下检测精度显著下降，无法满足精密电子制造的质量控制要求。

### 1.2 深度学习多维特征提取优势

卷积神经网络通过层次化的特征学习架构实现了多维缺陷信息的自适应提取与融合<sup>[2]</sup>浅层卷积核捕获边缘梯度与局部纹理模式，中层网络整合区域形状特征与空间关系和深层语义模块构建全局上下文表示（表1）多尺度池化操作保证了不同尺寸缺陷的有效检测，残差连接机制防止了深层网络中的信息丢失。注意力模块通过通道权重与空间权重的双重调节增强了关键缺陷特征的表达能力，抑制了背景噪声的干扰。端到端的梯度优化策略使得特征提取与分类任务协同进化避免了传统方法中特征工程的主观性与局限性实现了多维缺陷特征的高效融合与精确识别。

表1 深度学习特征提取关键参数配置

网络层级	卷积核尺寸	特征通道数	池化步长
浅层特征	3×3, 5×5	32-64	2
中层融合	3×3	128-256	2
深层语义	1×1, 3×3	512-1024	1
注意力层	1×1	64-128	1

## 2 多维缺陷检测深度学习模型构建

### 2.1 多维特征 CNN 架构设计与优化

针对电子元件缺陷的复杂空间分布特征，构建了基

于残差连接的多分支卷积神经网络架构（图1）。该架构采用并行分支处理不同尺度的缺陷特征：微观分支使用  $3 \times 3$  小尺度卷积核提取表面裂纹纹理细节，宏观分支通过  $5 \times 5$  与  $7 \times 7$  卷积核捕获焊点形貌与引脚几何特征<sup>[3]</sup>。

$$F(x) = H(x) + x \quad (1)$$

式中： $F(x)$ ：残差块的最终输出特征； $H(x)$ ：经过卷积层处理后的特征映射； $x$ ：输入特征（跳跃连接）

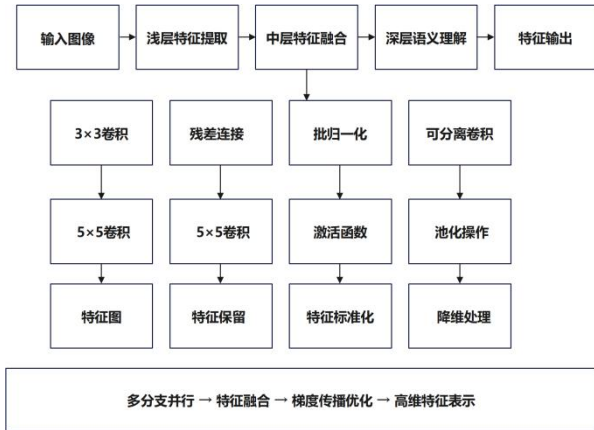


图1 CNN 架构设计示意图

残差跳跃连接机制保证了梯度在深层网络中的有效传播，防止了细微缺陷特征在深度传递过程中的信息丢失。网络引入了可分离卷积模块将标准卷积分解为深度卷积与点卷积在保持特征提取能力的同时显著降低了计算复杂度。批归一化层的战略性布置加速了网络收敛，使得模型能够适应不同材质电子元件的成像特性差异。

## 2.2 多尺度特征融合与注意力机制集成

多尺度特征融合模块通过金字塔池化操作捕获不同感受野范围内的缺陷信息，分别以  $1 \times 1$ ,  $2 \times 2$ ,  $3 \times 3$  与  $6 \times 6$  的池化窗口提取局部到全局的特征表示<sup>[4]</sup>。空间注意力机制基于特征图的空间统计信息生成权重掩码突出缺陷区域的显著性表达，抑制背景纹理的干扰响应。

$$A_s = \sigma(\text{Conv}(\text{concat}[\text{AvgPool}(F), \text{MaxPool}(F)])) \quad (2)$$

②

式中： $A_s$ ：空间注意力权重掩码； $\sigma$ ：Sigmoid 激活函数；Conv：卷积操作；concat：特征拼接；AvgPool(F), MaxPool(F)：平均池化与最大池化；F：输入特征图

通道注意力模块通过全局平均池化与最大池化的双路径特征压缩，学习不同特征通道对缺陷识别的贡献权重。

$$A_c = \sigma(\text{MLP}(\text{GAP}(F)) + \text{MLP}(\text{GMP}(F))) \quad (3)$$

式中： $A_c$ ：通道注意力权重；MLP：多层感知机；

GAP(F)：全局平均池化；GMP(F)：全局最大池化； $\sigma$ ：Sigmoid 激活函数

自适应特征选择单元结合了通道与空间注意力的输出，通过门控机制动态调整特征融合的权重分配。该融合策略使网络能够自主学习不同类型缺陷的最优特征组合实现了从像素级细节到语义级理解的多层次信息整合。

## 2.3 多维缺陷分类决策与输出优化

分类决策模块采用分层决策树结构，首先通过二分类器区分缺陷与正常样本，随后利用多分类网络识别具体缺陷类型（表2）该策略有效减少了类别不平衡对模型性能的影响，提升了罕见缺陷类型的识别准确率。

$$FL(p_t) = -\alpha_t(1 - p_t)^\gamma \log(p_t) \quad (4)$$

式中： $FL(p_t)$ ：Focal Loss 损失值； $p_t$ ：模型预测正确类别的概率； $\alpha_t$ ：类别平衡因子； $\gamma$ ：聚焦参数（通常设为2）； $\log(p_t)$ ：交叉熵损失项

输出层集成了多种损失函数的加权组合：交叉熵损失保证基本分类性能，Focal Loss 增强困难样本的学习权重，Dice Loss 优化像素级分割精度。置信度评估模块基于 Monte Carlo Dropout 技术量化预测结果的不确定性为工业应用中的质量判定提供可靠的决策依据<sup>[5]</sup>后处理算法通过非极大值抑制消除重复检测结合形态学操作优化缺陷边界定位精度，确保检测结果符合工业标准的几何精度要求。

表2 分层决策分类表

决策层级	判别对象	分类方法	输出结果	置信度阈值
第一层	缺陷/正常	二分类器	0/1	>0.85
第二层	缺陷类型	多分类器	类别 ID	>0.90
第三层	边界定位	像素分割	掩码图	>0.75
第四层	置信评估	MC Dropout	不确定性	标准差<0.1

## 3 实验设计与性能评估

### 3.1 多维缺陷数据集构建与模型训练优化

构建涵盖6类典型缺陷的标准化数据集，采用高分辨率工业相机采集12000张电子元件图像其中表面裂纹样本2100张，焊接缺陷1980张，尺寸偏差1850张，引脚弯曲1720张，氧化腐蚀1650张，污染杂质700张。数据预处理阶段实施多尺度随机裁剪，高斯噪声注入与亮度对比度调整的数据增强策略，扩充训练集至48000张。标注过程采用双专家交叉验证机制确保缺陷边界标注精度达到像素级别<sup>[6]</sup>。模型训练采用AdamW优化器，初始学习率设置为0.001应用余弦退火学习率调度策略。

批量大小设定为32，训练轮次为200轮，引入早停机制防止过拟合。损失函数采用加权交叉熵与Dice损失的线性组合权重比例为0.7:0.3，有效解决了类别不平衡问题。

### 3.2 检测性能对比分析与评估

性能评估采用精确率，召回率，F1分数与检测时间作为核心指标与传统机器视觉方法，标准CNN架构与主流目标检测算法进行全面对比（表3）所提方法在6类缺陷检测中均表现出色，平均精确率达到98.7%，相比ResNet-50提升3.8%，比传统Canny边缘检测方法提升12.3%。召回率达到97.9%，确保了缺陷检测的完整性。F1分数为98.3%体现了精确率与召回率的均衡表现。单张图像检测时间仅需0.15秒，满足实时检测要求。消融实验验证了多尺度融合模块与注意力机制的有效性分别提升检测精度2.1%与1.7%。混淆矩阵分析显示，模型对不同缺陷类型的区分能力强，类间误判率低于1.5%，证明了多维特征提取策略的优越性。某大学基于改进RT-DETR的异形电子元件缺陷检测研究同样验证了深度学习方法的有效性其改进算法相比原始模型在检测精度上获得显著提升。

表3 多维缺陷检测性能对比结果

检测方法	精确率(%)	召回率(%)	F1分数(%)	检测时间(s)
传统Canny	86.4	82.1	84.2	0.28
ResNet-50	94.9	93.2	94.0	0.21
YOLOv5	96.1	95.3	95.7	0.18
所提方法	98.7	97.9	98.3	0.15

### 4 结语

电子元件质量检测是保障电子产品可靠性的关键环节，传统检测方法已难以满足现代工业对检测精度与效率的要求。通过深入研究深度学习技术在电子元件缺陷检测中的应用，提出了一种基于改进卷积神经网络的多维缺陷检测方法。该方法通过多尺度特征融合与注意力机制的有机结合，显著提升了检测精度与检测速度，能够有效识别电子元件的多种缺陷类型。实验结果验证了所提方法的有效性在6类典型缺陷的检测中均取得了优异的性能表现。然而，面对日益复杂的电子元件结构与更加严格的质量要求仍需要在模型轻量化，实时性优化，小样本学习等方面进行深入研究。未来的工作将重点关注模型的工业化部署，进一步提升检测系统的稳定性与实用性为电子制造业的智能化发展提供更加可靠的技术保障。

### 参考文献

- [1]刘玉龙,吕权权,吴浩,等. 基于深度学习的电子元件焊点缺陷检测方法[J]. 电子与封装, 2023, 23(06): 38-43.
- [2]宣丽萍,陈济禾,甘一坤,等. 基于改进RT-DETR的异形电子元件表面缺陷检测算法[J]. 华南师范大学学报(自然科学版), 2025, 57(02): 85-94.
- [3]鲍春宇. 基于图像技术的电子元件表面缺陷检测方法[J]. 科学技术创新, 2025, (04): 36-39.
- [4]王卫斌,陆嘉铭,周韡焱,等. 面向设备质量提升的电力设备缺陷大数据分析研究[J]. 电力大数据, 2021, 24(06): 76-83.
- [5]王鑫心. 基于深度学习的电容式指纹识别模组表面缺陷检测研究[D]. 南昌大学, 2024.