文章编号:1000-1638(2026)05-0532-08 DOI:10.13484/j.nmgdxxbzk.20260509

基于零样本学习的光伏缺陷检测研究*

包雪琴[1,2],李 璐[1,2],于国晨[3]

(1. 包头轻工职业技术学院,内蒙古 包头 014030; 2. 韩国中部大学,韩国 首尔 10279;
3. 内蒙古大学电子信息工程学院,呼和浩特 010070)

摘要:光伏组件的缺陷会直接导致使用中的组件发电效率下降、产生短路和起火等安全风险问题。传统光伏组件缺陷检测方法常依赖人工标注数据,导致细微缺陷识别能力不足,难以适应大规模生产场景。本文提出一种基于零样本学习(Zero-shot learning)的光伏组件缺陷检测方法,建立改进的AnomalyCLIP检测模型,引入链式推理机制,构建特征观察-缺陷假设-证据分析-决策判断四阶段链式推理框架,设计光伏领域专属的特征-语义关联规则,采用ELPV基础数据集+腐蚀斑点补充样本的混合数据源完成训练。实验表明,该方法对训练中未出现的腐蚀斑点类别具有较好的泛化能力,召回率为83.7%,F_1分数为84.8%;在整体测试集上,其识别准确率达到88.6%,较传统AnomalyCLIP提升5.9个百分点。该方法实现了零样本下具有相似特征的光伏组件缺陷检测,能够显著降低检测成本,为光伏产业降本增效提供技术支撑。

关键词:光伏组件; 缺陷检测; 零样本学习; 链式推理

中图分类号:TM615; TP391.41 **文献标志码**:A

在碳达峰碳中和战略目标驱动下,光伏产业得到了迅速发展。国际可再生能源署报告指出,2024年全球光伏累计装机容量达1 865 GW,占新增可再生能源的77.25%[1]。光伏组件在生产和运行中易产生微裂纹、栅线断裂、热斑、表面污染等缺陷[2],这些问题不仅直接导致组件发电效率下降15%~30%[3],而且易引发温度上升风险[4],尤其是热斑缺陷可使局部温度骤升至200 ℃以上,造成火灾等事故[5]。2023年全球光伏行业隐性缺陷导致的故障占比超65%,因设备故障(含火灾)造成的直接经济损失达46亿美元[6]。当前检测技术的局限性已成为制约光伏产业降本增效的关键因素,因此,构建合理的缺陷检测体系是促进光伏产业高质量发展的迫切需求。

传统光伏组件缺陷检测方法以人工目视检查、电致发光成像、红外热成像和电学特性分析为核心技术手段[7]。其中,人工目视检查受检测人员经验差异影响,存在主观性强、效率低的问题;电致发光成像能有效揭示微裂纹、栅线断裂等电气不连续性缺陷,红外热成像可通过电阻损耗差异定位热斑区域[8],但二者对检测环境的光照、温度条件要求严苛。基于傅里叶变换的频域分析方法[9]与形态学操作方法[10],具有原理简单、硬件成本低的优势,是缺陷图像预处理的常用手段。郝泽兴等[11]引入自适应阈值策略以提升边缘检测精度,但该类传统图像处理方法对微裂纹细微纹理、热斑低对比度特征的捕捉能力不足。

近年来,深度学习技术在缺陷检测领域取得显著进展,其中卷积神经网络(CNN)与YOLO系列

* **收稿日期**:2026-05-20; **修回日期**:2026-08-31

基金项目:内蒙古自然科学基金项目(2024LHMS05039)

作者简介:包雪琴(1986—),女(蒙古族),内蒙古包头人,讲师,2023级博士研究生。主要从事电力智能信息处理研究。E-mail: 442687120@qq.com

通信作者:于国晨(1974—),男,内蒙古赤峰人,讲师,博士。主要从事电力智能信息处理研究。E-mail: yuguochen2020@163.com

目标检测算法凭借优异的特征提取与实时检测性能成为研究主流[12]。CNN的缺陷检测方法在特定缺陷识别任务中实现了92.3%的检测精度，但其性能高度依赖大规模标注样本，导致其工业场景下的数据制备成本居高不下。缺陷自动分类系统虽有效提升了检测流程的自动化效率，却受限于标注数据的分布特性，模型在跨场景、跨类型缺陷检测中的泛化能力表现不足[13]。基于YOLOv7的架构优化缺陷检测流程，通过微调模型特征融合模块与优化图像预处理环节，提升了户外复杂环境下热斑检测的自动化精度与鲁棒性[14]。通过构建YOLOv8n-GBE轻量化模型，结合Ghost卷积、BiFPN与ECA注意力机制，显著提升了多尺度光伏缺陷定位性能与识别精度[15]。但二者均未突破深度学习对大规模标注数据的依赖困境，仍面临标注成本高昂、新兴材料下未知缺陷适应性差的问题[16]。因此，亟须构建兼具低标注依赖与高泛化能力的缺陷检测框架，以适配光伏产业实际需求。

零样本学习（Zero-shot learning）技术为突破标注依赖困境提供了新路径，可以实现对未知缺陷类型的识别，但在光伏领域的适配性仍需优化[17]。属性向量模型通过人工定义“线性纹理”“局部高亮”等缺陷属性实现跨类别迁移，主观性强导致特征刻画不全面[18]。SuperCLIP针对通用对比语言图像预训练（CLIP）在遥感零样本分类存在的域偏移问题，引入超分辨率与语义属性引导Transformer模块，优化图像-文本跨模态嵌入，提升遥感未见场景类别的识别性能[19]。AnomalyCLIP依托通用提示捕捉正常特征，虽在工业异常检测中F_1分数达80.3%，但因缺乏光伏领域知识，对宽度＜5像素的微裂纹识别不足[20]。WinCLIP通过窗口特征聚合与组合提示集成将模型鲁棒性提升8%，却无法适配光伏缺陷的空间分布规律与形成机制，对未见过的腐蚀斑点等缺陷召回率不足70%[21]。上述模型均未构建光伏专属特征-语义关联规则，致使细微缺陷检测召回率偏低。

为突破传统零样本方法的领域适配性局限，本文提出一种基于零样本学习的光伏组件缺陷检测方法，首先构建改进型AnomalyCLIP检测模型，引入链式推理机制并搭建四阶段推理框架；然后采用ELPV数据集[22]完成模型训练；最后通过实验验证所提方法的可行性。

1　零样本光伏组件缺陷检测框架

本文构建的零样本光伏组件缺陷检测框架由图像预处理、跨模态特征提取、链式推理提示、零样本决策4个模块构成，如图1所示。

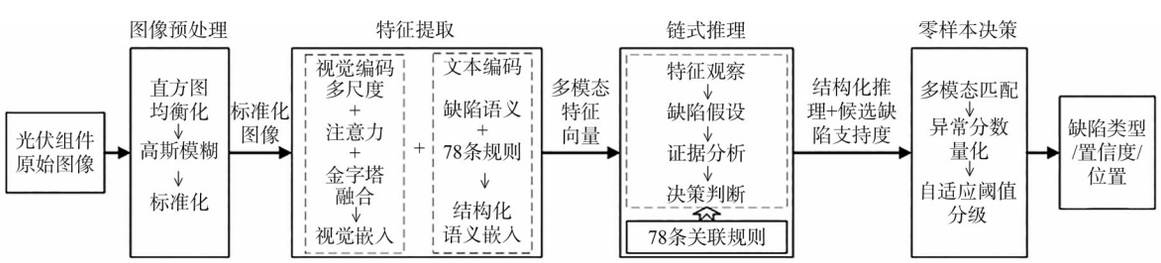


图1　零样本检测结构框架

Fig. 1　Zero-shot detection architecture

1）图像预处理：针对光伏组件图像光照不均、噪声干扰的问题，设计三级预处理流程，通过直方图均衡化消除光照不均影响，结合高斯模糊抑制高频噪声，将输入图像标准化为224×224像素尺寸。该模块为后续多尺度特征融合提供统一、高质量的标准化输入。

2）特征提取：基于改进的AnomalyCLIP构建领域适配的跨模态特征体系，视觉编码器提取第3、6、9、12层多尺度特征，兼顾局部细节与全局轮廓；文本编码器对缺陷语义描述精准编码；通过对比学习实现视觉-语义特征对齐，最终融合形成多模态特征。该模块有效弥补单一尺度信息缺失，为链式推理提供统一语义空间与多维特征支撑。

3）链式推理：以包含78条特征-缺陷关联规则的光伏缺陷知识库为核心，将多模态融合特征转化为可解释的结构化推理逻辑，模拟专家“观察-假设-验证-决策”的诊断过程，有效解决零样本检测

“推理不可解释”“特征-语义关联薄弱”的问题。推理流程分为4步:特征观察提取异常信息,依据相似度生成前3类缺陷假设,基于领域规则完成证据分析与置信度计算,最后结合风险等级完成最终决策判断。

4)零样本决策:以链式推理生成的结构化提示为输入,通过余弦相似度计算实现视觉特征与语义库的高效匹配;融合多阶段支持度得到0至1区间的综合异常评分;基于K-means聚类分析缺陷风险等级,动态设定0.65~0.85自适应阈值,最终实现缺陷类型识别与空间定位。

2 链式推理的AnomalyCLIP模型检测

2.1 改进的AnomalyCLIP模型

为解决原生AnomalyCLIP模型在光伏组件缺陷检测中领域适配性差、细微缺陷捕捉弱、特征语义关联不足的问题,本文明确其核心架构后,从跨模态对齐、特征提取、领域知识融合和损失函数4个方面进行光伏专属改进,结合LoRA低秩适配技术微调,构建光伏组件零样本缺陷检测专用模型,为后续链式推理提供可靠支撑。

原生AnomalyCLIP以冻结CLIP视觉-文本双编码器为核心,通过构建正常/异常两类目标无关可学习文本提示,并借助全局-局部联合损失实现通用异常检测[20]。训练过程仅优化文本提示嵌入,缺少领域专属设计与结构化知识引导,难以精准捕捉微裂纹、隐裂、腐蚀斑点等光伏典型细微缺陷。

针对上述局限,本文保留原生模型的双编码器与监督框架,该框架中全局损失负责图像级的异常判定,局部损失负责像素级的异常区域定位。在此基础上,引入光伏领域知识与多尺度特征增强机制,完成从“通用异常检测”到“光伏专用缺陷推理”的适配升级。改进后的AnomalyCLIP模型架构如图2所示。

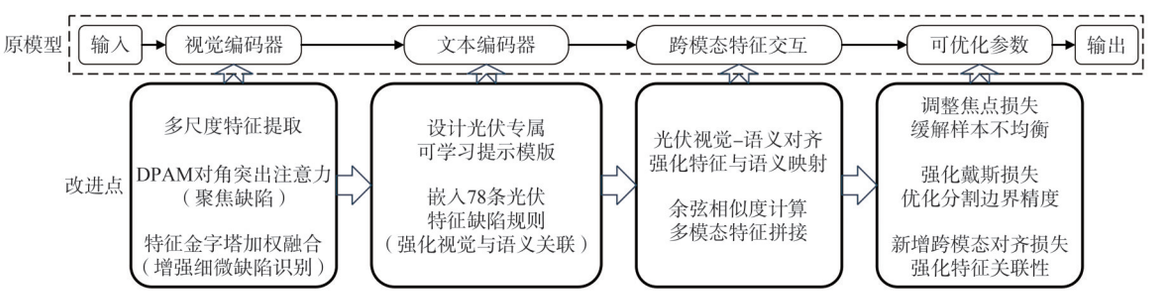


图2 改进后的AnomalyCLIP模型架构

Fig. 2 Architecture of the improved AnomalyCLIP model

2.2 链式推理设计

在改进模型的基础上,为实现精准且可解释的缺陷检测,构建特征观察-缺陷假设-证据分析-决策判断的四阶段链式推理机制,将视觉特征、领域知识与逻辑判断进行结构化融合。推理框架如图3所示。

1)特征观察:将图像视觉异常转化为结构化、可量化的观测描述。模型在提示模板引导下,提取颜色、形状、纹理等关键视觉特征,并与视觉特征知识库进行匹配,输出标准化异常观测结果,表达式为

$$O = F_{\text{obs}}(I, K_{\text{visual}})$$

式中,I为输入图像;K_{visual}为视觉特征知识库;F_{obs}为特征观察函数,用于提取图像与知识库之间的特征偏差;O为结构化观测结果,包含异常位置、类型和量化特征。

2)缺陷假设:基于观测结果O,模型结合缺陷类型知识库K_{defect}对潜在缺陷类型进行匹配、打分与排序,生成高置信度候选缺陷假设集合,表达式为

$$H = \{h_1, h_2, \cdots, h_k\} = F_{\text{hyp}}(O, K_{\text{defect}})$$

式中，K_{defect}为缺陷类型知识库；F_{hyp}为缺陷假设生成函数，用于基于特征相似度完成的候选缺陷筛选与排序；H为按置信度降序排列的前k个缺陷假设（$k=3,4,5$）。

3）证据分析：对每个候选缺陷h_i进行量化验证，评估其与观测特征、空间分布、领域规则的一致性，输出支持度得分，为最终决策提供逻辑依据，表达式为

$$E_i = F_{\text{eval}}(h_i, o, K_{\text{relation}})$$

式中，h_i为i个候选缺陷假设；o为结构化观测结果；K_{relation}为包含78条规则的特征缺陷关联知识库；F_{eval}为证据评估函数，综合特征匹配度、空间合理性、干扰排除性进行量化；E_i为第i个缺陷假设的支持度，输出值范围在0～1之间，值越高表示可信度越高。

4）决策判断：综合所有候选缺陷的支持度，结合动态阈值完成最终判定，输出是否存在缺陷和缺陷类别，表达式为

$$D = F_{\text{decide}}(\{h_i, E_j\}, \tau)$$

式中，$\{h_i\}$为候选缺陷假设集合；$\{E_j\}$为各假设对应的支持度；τ为基于缺陷风险等级自适应设定的动态决策阈值；F_{decide}为最终决策函数；D为最终检测结果，输出为缺陷存在/不存在以及对应类别。

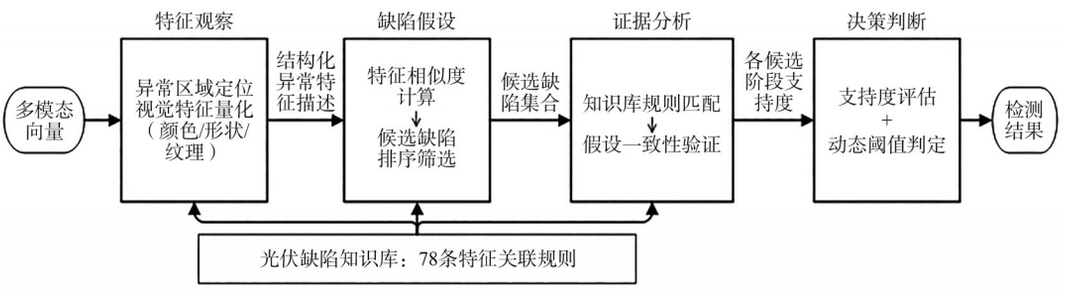


图3　四阶段链式推理框架

Fig. 3　Four-stage chained reasoning framework

3　仿真验证

3.1　实验环境

实验数据源自ELPV公开数据集，包含2 624张分辨率为300×300的光伏组件缺陷电致发光图像，图像均标注缺陷类型、位置和损伤程度，数据覆盖微裂纹、断栅等典型缺陷和正常样本。数据集按照7∶3划分为训练集1 837张、测试集787张，用于模型常规缺陷检测。为验证模型零样本泛化能力，补充现场运维采集的390张“腐蚀斑点”缺陷样本作为未知缺陷测试集，该部分样本不参与模型训练，仅用于零样本场景下“未见过缺陷”的泛化性能测试。

实验部署在Intel Xeon Platinum 8360Y CPU、512 GB内存和80 GB显存NVIDIA A100 GPU的服务器环境，基于PyTorch 1.10.0与CUDA 11.3实现GPU加速，使用Transformers 4.18.0、OpenCV 4.5.5和NumPy 1.21.5等工具库。

3.2　评估指标

采用以下6项指标全面评估系统性能：

1）准确率（A_{cc}）：正确识别缺陷/正常样本的比例，反映模型整体检测可靠性，公式为

$$A_{\text{cc}} = (T_{\text{P}} + T_{\text{N}})/(T_{\text{P}} + T_{\text{N}} + F_{\text{P}} + F_{\text{N}}) \tag{1}$$

2）精确率（P_{rec}）：检测为缺陷的样本中实际为缺陷的比例，控制误检成本，公式为

$$P_{\text{rec}} = T_{\text{P}}/(T_{\text{P}} + F_{\text{P}}) \tag{2}$$

3）召回率（R_{ec}）：实际为缺陷的样本中被成功检测的比例，控制漏检风险，公式为

$$R_{\text{ec}} = T_{\text{P}}/(T_{\text{P}} + F_{\text{N}}) \tag{3}$$

4）F_1分数：综合精确率与召回率的调和均值，用于平衡误检与漏检，公式为

$$F_1 = 2 \times (P_{rec} \times R_{ec}) / (P_{rec} + R_{ec}) \tag{4}$$

5) AUC(Area under curve):反映模型区分缺陷与正常样本的能力,数值越高模型鲁棒性越强。

6) 推理一致性(C_{infer}):量化各推理阶段中间结果与最终决策的偏差,直接反映检测过程的可解释性,公式为

$$C_{infer} = 1 - \frac{1}{N} \sum_{i=1}^{N} | D_{final} - D_i | \tag{5}$$

式(1)—(3)中,T_P为真阳性,T_N为真阴性,F_P为假阳性,F_N为假阴性,式(5)中N为测试样本总数,D_{final}为最终决策结果,D_i为第i个推理阶段的中间结果。

3.3 实验结果分析

3.3.1 腐蚀斑点的零样本缺陷检测性能

为验证本文提出的ZSPV-Detect(Zero-shot photovoltaic defect)方法的零样本泛化能力,依托零样本学习无需标注数据即可检测未知缺陷类型的核心优势,在仅含腐蚀斑点、无任何训练标注的零样本缺陷测试子集上开展实验,重点评估模型对未知缺陷的识别性能,同时与现有零样本检测方法进行对比,实验结果如表1所示。

表1 腐蚀斑点的检测性能

Table 1 Detection performance of corrosion spots

方法	精确率/%	召回率/%	F_1分数/%
AnomalyCLIP	78.6	72.3	75.3
WinCLIP	81.5	78.9	80.2
SDP	80.8	77.5	79.1
ZSPV-Detect(链式推理)	85.9	83.7	84.8

现有零样本方法(AnomalyCLIP、WinCLIP、SDP)的F_1分数均低于81%,核心原因是其缺乏光伏领域专属的特征-语义关联规则,无法有效建立腐蚀斑点的视觉特征与语义描述之间的映射关系,导致对未知缺陷的识别精度有限。

本文提出的方法在腐蚀斑点零样本检测中表现最优,F_1分数达84.8%,精确率与召回率均突破83%,证明本文方法能够实现未知缺陷的精准检测,零样本泛化能力显著优于现有方法。

3.3.2 各种缺陷检测方法对比

为了验证本文提出的方法对已知缺陷(微裂纹、断栅)检测的有效性和性能优势,选取不同类型的基线方法进行对比,所有基线模型均基于相同硬件环境训练,训练轮数、学习率等超参数保持一致。传统无监督方法包括One-Class SVM和Isolation Forest,深度学习方法采用Deep SVDD方法,零样本方法包括AnomalyCLIP、WinCLIP和SDP。实验重点评估各方法在已知缺陷测试子集上的整体性能,同时针对性分析微裂纹(宽度<5像素)的检测性能,以验证本文方法对细微缺陷的识别能力,实验结果如表2所示。

从表2可以看出本文方法与各类基线方法的综合性能,核心结论如下:

1) 传统无监督方法(One-Class SVM、Isolation Forest)仅实现异常二分类判别,无法完成缺陷类型识别,对细微特征表征能力不足,不适用零样本场景,$F_1 \leqslant 67.6\%$。

2) 深度学习有监督方法(Deep SVDD)依赖大规模标注数据,泛化性受限,仅能识别训练集已知缺陷,对未知缺陷泛化能力弱,F_1值约为73%。

3) 现有零样本方法(AnomalyCLIP、WinCLIP、SDP)具备一定泛化能力,但缺乏光伏领域专属知识与特征-语义关联设计,对细微缺陷的识别能力有限,F_1值在80.3%~82.3%之间。

4)本文提出的ZSPV-Detect(链式推理)性能最优,准确率为88.6%,较传统One-Class SVM提

升 20.2 个百分点，较 AnomalyCLIP 提升 5.9 个百分点；F_1 分数为 86.2%，较传统 One-Class SVM 提升 22.3 个百分点，较 AnomalyCLIP 提升 5.9 个百分点。核心原因是链式推理强化了光伏专属特征-语义关联，多尺度特征提取提升了模型对细微缺陷的识别精度。

5）通过对比 ZSPV-Detect 单阶段与链式推理版本的性能差异，进一步验证了链式推理的四阶段框架可有效提升模型的推理严谨性与特征匹配精度。

表 2　ELPV 数据集上的性能比较

Table 2　Performance comparison on the ELPV dataset

方法	准确率/%	精确率/%	召回率/%	F_1 分数/%	AUC
One-Class SVM	68.4	65.2	62.7	63.9	0.704
Isolation Forest	72.1	68.9	66.3	67.6	0.742
Deep SVDD	76.3	74.5	71.8	73.1	0.783
AnomalyCLIP	82.7	81.2	79.4	80.3	0.856
WinCLIP	84.2	83.5	81.1	82.3	0.869
SDP	83.9	82.8	80.7	81.7	0.863
ZSPV-Detect（单阶段）	84.5	83.8	80.9	82.3	0.871
ZSPV-Detect（链式推理）	88.6	87.3	85.1	86.2	0.905

3.3.3　链式推理的各部分作用

为验证链式推理各阶段对模型性能的贡献，设计消融实验（表 3），逐一移除特征观察、缺陷假设、证据分析、决策判断 4 个推理环节，在已知缺陷测试子集上分别评估各消融变体性能。通过对比完整模型与各消融模型的性能差异，验证了链式推理四阶段协同机制是提升检测效果的关键。

表 3　移除不同推理阶段对系统性能的影响

Table 3　Impact of removing different inference stages on system performance

系统配置	准确率/%	精确率/%	召回率/%	F_1 分数/%	AUC
完整 ZSPV-Detect	88.6	87.3	85.1	86.2	0.905
移除特征观察	79.2	78.5	76.8	77.6	0.842
移除缺陷假设	82.1	80.9	79.3	80.1	0.865
移除证据分析	85.4	84.2	82.7	83.4	0.881
移除决策判断	86.8	85.7	83.9	84.8	0.893
单阶段提示	84.5	83.8	80.9	82.3	0.871

结合表 3 消融实验结果，结论如下：

1）移除特征观察阶段影响最大：F_1 从 86.2% 降至 77.6%，因该阶段量化缺陷的结构化特征为模型推理提供精准依据，缺失后特征与语义匹配误差增大。

2）移除证据分析阶段，F_1 降至 83.4%，证明 78 条专属关联规则能有效筛选虚假假设，强化模型推理严谨性。

3）移除决策判断阶段或采用单阶段提示，性能均低于完整模型，验证四阶段闭环的必要性，其可模拟专家思维，保障模型推理可解释性与结果可靠性。

4）所有消融模型的性能均不及完整 ZSPV-Detect 模型，证明链式推理四阶段框架的协同作用是提升模型已知缺陷检测精度与零样本泛化能力的关键，同时也验证了各阶段设计的合理性与必要性。

4 结论

光伏组件缺陷检测是有效降低发电量损耗、保障电站运行安全的重要手段。本文提出一种融合链式推理的零样本光伏缺陷检测方法,基于改进的AnomalyCLIP模型搭建四阶段可解释推理框架,依托多尺度特征提取与自适应阈值实现未知缺陷精准识别,克服了传统检测标注依赖度高、细微缺陷识别差、推理逻辑不透明的短板。实验表明,对未见过的腐蚀斑点检测过程中,F_1分数达到84.8%,显著提升了模型对未知缺陷的泛化能力;整体准确率为88.6%,较AnomalyCLIP提升5.9个百分点,该方法推理过程可解释、可适配光伏生产质检与电站运维场景,为行业降本增效提供可行技术方案。

面向光伏工艺迭代与长期工业落地,本方法仍存在优化空间:现有静态人工规则库存在新工艺适配成本递增问题,后续可引入多智能体协同推理搭配LoRA微调实现规则自适应更新;同时可搭建少样本持续学习闭环,利用产线复核样本迭代优化模型;仅依靠扩充规则提升模型识别精度存在边际递减效应,未来可通过强化视觉预训练基座,生成扩充细微缺陷样本从而突破性能瓶颈。

参考文献:

[1] IRENA. Renewable capacity statistics 2026[R]. Abu Dhabi:International Renewable Energy Agency,2026.
[2] 张妍,裴兴豪,李冰,等. 一种基于航拍红外图像的光伏热斑故障分类检测方法[J]. 太阳能学报,2024,45(9):353-359.
[3] 杨博,赵勇,谢小军,等. PERC电池EL黑斑对于光伏组件性能的影响[J]. 太阳能学报,2020,41(12):97-102.
[4] 彭自然,张颖清,肖伸平. 基于YOLOv5的太阳电池表面缺陷检测[J]. 太阳能学报,2024,45(6):368-375.
[5] 王方政,刘喜泉,陈浈斐,等. 基于串联电阻估计的光伏阵列热斑故障诊断方法[J]. 智慧电力,2022,50(10):61-69.
[6] IEA-PVPS. Snapshot of global PV markets 2025[R]. Paris:IEA Photovoltaic Power Systems Programme,2025.
[7] 余德坤,易雅琴. 基于改进DeepLabV3+的光伏板识别检测应用[J]. 北京测绘,2025,39(11):1567-1573.
[8] Korkmaz D,Acikgoz H. An efficient fault classification method in solar photovoltaic modules using transfer learning and multi-scale convolutional neural network[J]. Engineering Applications of Artificial Intelligence,2022,113:104959.
[9] 赖天舒,刘怀广,汤勃,等. 多特征融合的太阳能电池片缺陷检测[J]. 应用光学,2023,44(3):605-613.
[10] 王宇,孙智权,赵不贿. 基于机器视觉的太阳能电池硅片隐裂检测[J]. 组合机床与自动化加工技术,2019(12):95-97.
[11] 郝泽兴,郭改枝,代妍玮,等. 一种改进Canny算子的边缘检测算法[J]. 内蒙古大学学报(自然科学版),2022,53(5):530-537.
[12] 周颖,毛立,张燕,等. 改进CNN的太阳电池缺陷识别方法研究[J]. 太阳能学报,2020,41(12):69-76.
[13] Wang J,Bi L,Sun P,et al. Deep-learning-based automatic detection of photovoltaic cell defects in electroluminescence images[J]. Sensors,2023,23(1):297.
[14] 王道累,李超,李明山,等. 基于深度卷积神经网络的光伏组件热斑检测[J]. 太阳能学报,2022,43(1):412-417.
[15] Yeddula L R,Pallakonda A,Raj R D A,et al. YOLOv8n-GBE:A hybrid YOLOv8n model with ghost convolutions and BiFPN-ECA attention for solar PV defect localization[J]. IEEE Access,2025(13):114012-114028.
[16] 陈笛,彭秋志,黄培依,等. 采用注意力机制与改进YOLOv5的光伏用地检测[J]. 自然资源遥感,2023,35(4):90-95.
[17] Su B,Chen H,Chen P,et al. Deep learning-based solar-cell manufacturing defect detection with complementary attention network[J]. IEEE Transactions on Industrial Informatics,2021,17(6):4084-4095.
[18] Peng P,Tian Y,Xiang T,et al. Joint semantic and latent attribute modelling for cross-class transfer learning[J]. IEEE transactions on pattern analysis and machine intelligence,2017,40(7):1625-1638.
[19] Rambabu D,Gayathri C,Datla R,et al. SuperCLIP:Semantic attribute-guided transformer with super-resolution and

CLIP for zero-shot remote sensing scene classification[J]. IEEE Geoscience and Remote Sensing Letters, 2025, 22: 1-5.

[20] Zhou Q, Pang G, Tian Y, et al. AnomalyCLIP: Object-agnostic prompt learning for zero-shot anomaly detection [C]//Proceedings of the International Conference on Learning Representations. Vienna, Austria: ICLR, 2024: 49705-49737.

[21] Chen Y, Xu Y, Wang T, et al. Self-supervised CLIP-guided for few-shot industrial anomaly detection[J]. IEEE Transactions on Instrumentation and Measurement, 2026, 75: 1-16.

[22] Deitsch S, Buerhop-Lutz C, Sovetkin E, et al. Segmentation of photovoltaic module cells in uncalibrated electroluminescence images[J]. Machine Vision and Applications, 2021, 32(4): 84.

Research on Photovoltaic Defect Detection Based on Zero-Shot Learning

BAO Xueqin[1,2], LI Lu[1,2], YU Guochen[3]

(1. *Baotou Light Industry Vocational Technical College*, *Baotou* 014030, *China*;
2. *Joongbu University*, *Seoul* 10279, *Korea*;
3. *School of Electronic Information Engineering*, *Inner Mongolia University*, *Hohhot* 010070, *China*)

Abstract: Defects in photovoltaic modules can directly cause reduced power generation efficiency of modules during operation and lead to safety risks such as short circuits and fires. Traditional defect detection methods for photovoltaic modules often rely on manually annotated data, lack the ability to identify subtle defects, and are difficult to adapt to large-scale production scenarios. A zero-shot learning-based defect detection method for photovoltaic modules is proposed, an improved AnomalyCLIP detection model is established, a chain reasoning mechanism is introduced, and a four-stage reasoning framework consisting of feature observation-defect hypothesis-evidence analysis-decision judgment is constructed. We also design feature-semantic association rules exclusive to the photovoltaic field and use a hybrid data source of ELPV basic dataset+corroded spot supplementary samples for training. Experiments show that the proposed method exhibits good generalization ability for corroded spot categories that were not seen during training, achieving a recall of 83.7% and an F_1 score of 84.8%; on the overall test set, its recognition accuracy reaches 88.6%, which is 5.9 percentage points higher than the traditional AnomalyCLIP method. The method realizes defect detection of photovoltaic modules with similar characteristics under zero-shot conditions, can significantly reduce detection costs, and provides technical support for cost reduction and efficiency improvement in the photovoltaic industry.

Key words: photovoltaic module; defect detection; zero-shot learning; chain-of-reasoning