



团 体 标 准

T/CES XXX-XXXX

输电巡检图像零样本缺陷检测技术导则

Technical Guidelines for Zero-Shot Defect Detection in Power
Transmission Inspection Images

(征求意见稿)

XXXX-XX-XX 发布

XXXX-XX-XX 实施

中国电工技术学会 发布

目 次

目 次	I
前 言	III
1 范围	4
2 规范性引用文件	4
3 术语和定义	4
4 符号、代号和缩略语	5
5 总体技术架构	6
5.1 零样本检测模型构建总体架构	6
5.2 零样本检测模型推理路径	6
5.3 输电业务场景与技术映射要求	7
6 数据采集	7
6.1 设备巡检视觉数据采集	7
6.2 设备巡检文本数据采集	8
6.3 公开数据采集	8
7 数据清洗	9
7.1 设备巡检视觉数据清洗	9
7.2 设备巡检文本数据清洗	10
8 数据标注	10
8.1 视觉图像数据标注	10
8.2 图文联合数据标注	10
8.3 数据增广	10
9 模型预训练	11
9.1 图像深层语义表征能力要求	11
9.2 图文跨模态语义对齐要求	11
9.3 部件拓扑结构与逻辑推理要求	12
9.4 预训练数据与质量管控要求	12
10 模型迁移与微调	12
10.1 总体要求	12
10.2 差异化微调策略	13

11 模型零样本检测能力多维度能力评测	13
11.1 评测维度	13
11.2 评测指标	13
11.3 评价数据集来源与构建规范	14
11.4 评测方法	15
12 模型部署	15
12.1 计算环境与资源适配	15
12.2 安全与隐私保护体系	16
12.3 推理优化与性能提升	16
12.4 多环境部署与服务化架构	16
12.5 生命周期管理与版本发布	17
12.6 部署阶段的安全与合规要求	17
13 标准的实施与维护	17
13.1 复审周期	17
13.2 临时修订机制	17
13.3 复审结论	17
附录 A（资料性） 输电部件锈蚀缺陷零样本检测模型开发示例	18
附录 B（资料性） 评测指标计算公式	20
附录 C（资料性） 电力设备部件拓扑关系分类、属性定义及建模参考	25
附录 D（资料性） 电力专业语义模板库构建规范示例	26
附录 E（资料性） 架空线路零样本缺陷检测成功案例	28

前 言

本文件按照 GB/T 1.1—2020《标准化工作导则 第1部分：标准化文件的结构和起草规则》给出的规则起草。

请注意本文件的某些内容可能涉及专利，本文件的发布机构不承担识别这些专利的责任。

本文件由中国电工技术学会提出。

本文件由中国电工技术学会标准工作委员会能源智慧化工作组归口。

本文件起草单位：国网冀北电力有限公司、国网冀北电力有限公司技能培训中心、南京土星信息科技有限公司、华北电力大学（保定）、国网冀北电力有限公司唐山供电公司、国网四川省电力公司电力科学研究院、天津大学、北京御航智能科技有限公司、中科方寸知微（南京）科技有限公司。

本文件主要起草人：周国亮、刘敏、吴佳、黄小龙、齐宇诺、刘朴焯、刘慧、郑恽、王红旭、徐铮、籍天明、康家玮、刘世光、李刚、郭晨晨、刘志明、张凌浩、弋沛玉、胡彬、郭大伟、高松鹤、姜世浩、马昕远、黄锋、陈海洋、周道辰、潘洪涛、王育志、刘博。

本文件为首次发布。

输电巡检图像零样本缺陷检测技术导则

1 范围

本文件规定了架空线路输电巡检图像零样本缺陷检测的总体技术框架、数据采集、数据清洗、数据标注、模型预训练与微调、模型评测及模型部署等技术要求。

本文件适用于指导架空线路输电巡检图像零样本缺陷检测模型的构建、应用及辅助研判工作。

2 规范性引用文件

下列文件中的内容通过文中的规范性引用而构成本文件必不可少的条款。其中，注日期的引用文件，仅该日期对应的版本适用于本文件。不注日期的引用文件，其最新版本（包括所有的修改单）适用于本文件。

GB/T	42755—2023	人工智能 面向机器学习的数据标注规程
GB/T	45288.1—2025	人工智能 大模型 第1部分：通用部分
GB/T	45288.2—2025	人工智能 大模型 第2部分：评测指标与方法
GB/T	45288.3—2025	人工智能 大模型 第3部分：服务能力与成熟度评估
DL/T	2691—2023	电网设备缺陷智能识别技术导则
T/CES	129—2022	电力人工智能平台样本规范
T/CES	149—2022	输电线路金具与变电站设备图像样本标注要求
T/CES	208—2023	电力视觉检测算法评价方法
T/CES	277—2024	电力人工智能样本增广技术架构要求
T/CES	278—2024	面向电力行业的图像检测识别系统技术要求
T/CES	289—2024	电力人工智能模型场景化评价指南

3 术语和定义

下列术语和定义适用于本文件。

3.1

零样本缺陷检测 zero-shot defect detection

一种无需在训练集中包含目标缺陷样本，即可基于语义描述、特征外推或跨模态知识实现缺陷识别的检测方法，能够对未见过的缺陷类型或未出现过的设备部件上的已知缺陷进行推理判断。

3.2

跨部件泛化 cross-component generalization

指模型能够将已知部件上的缺陷识别能力推广至外观、材质、结构特征相似但训练集中未出现的设备部件上，实现跨设备、跨结构的缺陷识别能力。

3.3

未知缺陷 unknown defect

指未在训练集中出现、模型未见过的缺陷类型或异常模式，通常缺乏明确的样本标签与类别先验，需要通过语义推理或跨模态对齐实现识别。

3.4

部件拓扑关系 component topology

指电力设备内部及设备间部件的空间结构、连接方式、相对位置及功能关系，如层级关系、上下游关系或依赖关系等，用于辅助判断部件是否缺失、错位或组合异常。

3.5

图像区域特征 image region feature

指从图像中提取的局部区域特征，包括设备部件的纹理、形状、关键点、边缘特征及空间分布等，用于缺陷定位与特征比对。

3.6

文本编码器 text encoder

一种将输入的缺陷描述、部件名称、空间关系词或其他开放词汇提示转换为特征向量的深度神经网络，用于提取与视觉特征对齐的文本语义信息，通常基于 Transformer 架构构建，是实现零样本缺陷检测与结构推理的关键多模态组件。

3.7

跨模态对齐 cross-modal alignment

指将图像、文本、设备结构信息等不同模态的特征映射到共同的语义空间，使模型能够基于语义关联实现缺陷理解与推理。

3.8

图像编码器 image encoder

一种将输入巡检图像转换为特征向量的深度神经网络，用于提取设备部件及缺陷的视觉语义信息，可基于 CNN、Transformer 等结构构建。

3.9

拓扑推理 topology reasoning

基于部件之间的结构、相对位置及逻辑关系，通过对比真实结构与预期结构，实现缺失、错装、遗漏等结构性缺陷的识别方法。

3.10

缺陷语义描述 defect textual description

指通过人为或模型生成的、用于表示缺陷类别、表现特征、上下文环境的文本描述，为零样本检测提供语义先验知识。

3.11

特征投影 feature projection

指将视觉特征映射到与文本或知识库一致的语义空间，使模型能够基于相同坐标系进行相似度计算或语义匹配。

3.12

全量微调 full fine-tuning

对模型的全部参数进行更新，可最大程度提升模型在特定任务下的判别能力，适用于复杂结构、细粒度目标和高安全性要求的缺陷分析任务。

3.13

LoRA 微调 low-rank adaptation

LoRA 通过引入低秩适配矩阵进行参数高效更新，可在保持主模型性能稳定的前提下，快速适配不同场景的巡检需求。

3.14

适配器微调 adapter tuning

通过在模型内部插入轻量级适配器模块实现局部参数更新，使模型具备用于任务扩展和结构性推理的能力。

3.15

结构化提示微调 structural prompting

通过将输电设备的结构拓扑、部件连接关系或层级结构以结构化提示方式注入模型，使其具备基于结构逻辑进行推理的能力。

4 符号、代号和缩略语

下列符号、代号和缩略语适用于本文件。

AUC: 曲线下面积 (Area Under Curve)

CLIP: 对比语言—图像预训练模型 (Contrastive Language—Image Pre-training)

ZSL: 零样本学习 (Zero-Shot Learning)

ZSD: 零样本检测 (Zero-Shot Detection)

LLM: 大语言模型 (Large Language Model)
LoRA: 低秩适应 (Low-Rank Adaptation)
MLLM: 多模态大模型 (Multimodal Large Language Model)

5 总体技术架构

5.1 零样本检测模型构建总体架构

5.1.1 总体要求

在电网设备巡检领域，基于多模态大模型的语义融合机理，构建数据特征与设备缺陷的映射关系。结合跨模态对齐技术实现未知缺陷的零样本识别，还可引入巡检图像缺陷检测智能体。

5.1.2 模型架构

在电网设备巡检缺陷检测领域构建零样本检测模型需要考虑的因素，包括数据采集、数据清洗、数据标注、模型预训练与微调、模型评测和模型部署等环节，各环节逻辑关系如图 1 所示，任务构建示例详见附录 A。

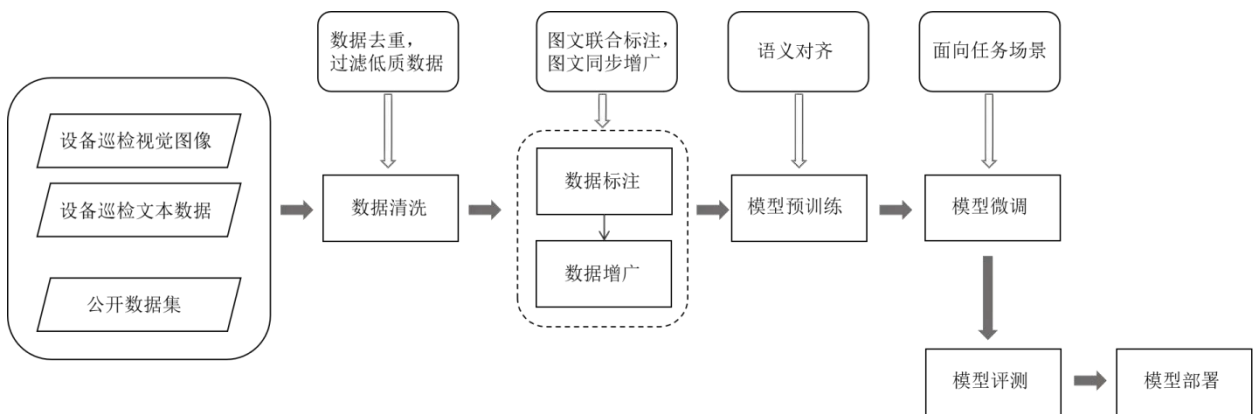


图1 零样本检测模型构建总体架构图

5.2 零样本检测模型推理路径

5.2.1 总体要求

零样本检测模型的推理路径应包含图像区域特征推理与部件拓扑关系推理两个方面，以实现未知缺陷的综合识别能力。模型应能够在缺乏目标缺陷样本的情况下，基于语义先验和跨模态对齐机制完成缺陷推理。

5.2.2 基于图像区域特征的缺陷识别路径

模型应通过对巡检图像中局部区域的视觉特征进行编码与分析，实现对未知缺陷的识别。基于图像区域特征的推理路径应覆盖以下两类未知缺陷场景：

a) 已知缺陷类型的跨部件泛化。

模型应能够将训练集中已出现的缺陷类型，从已见部件类型（如部件类型 A、B、C）泛化至训练集中未出现但结构或功能相似的部件类型（如部件类型 D、E），实现跨部件类型缺陷识别；

b) 全新缺陷类型的识别。

模型宜具备识别训练集中未出现的缺陷类别的能力，并基于语义描述、特征相似性或对比学习机制进行推理判断。

模型的区域特征编码应保持对纹理、结构、颜色、边缘等视觉要素的敏感性，以支持在弱样本或零样本条件下的特征外推能力。

5.2.3 基于部件拓扑关系的结构完整性分析路径

模型应利用设备部件之间的拓扑结构关系,对部件的空间位置、连接方式及组合状态进行推理分析。模型的拓扑推理应至少包括以下内容:

- a) 部件是否存在缺失、脱落;
- b) 部件是否存在错装或错位;

部件拓扑关系的建模宜基于设备结构模型、图结构编码器或空间几何关系等方法构建统一的拓扑推理框架。

5.3 输电业务场景与技术映射要求

5.3.1 典型缺陷业务特征库构建

模型应建立涵盖输电线路典型缺陷(如绝缘子自爆、导线断股、金具锈蚀、杆塔倾斜等)的业务特征库。特征描述不仅包含视觉纹理,还应融合电力行业标准(如 DL/T 741)中的缺陷定级标准(一般、严重、危急)。

5.3.2 复杂环境业务适配

针对输电巡检特有的大雾、雨雪及逆光场景,模型应具备环境感知能力,自动调整推理阈值。例如,在浓雾环境下,应降低对细微裂纹的检测权重,优先关注结构性缺失(如防振锤脱落)。

5.3.3 部件拓扑业务逻辑约束

引入输电设备层级关系(塔材→横担→绝缘子串→金具→导线),模型推理需符合物理连接逻辑。严禁出现违反物理常识的检测结果(如:导线悬浮于空中无支撑、绝缘子串连接顺序错误等)。

6 数据采集

6.1 设备巡检视觉数据采集

6.1.1 采集范围

设备巡检视觉类数据采集应根据输电线路巡检场景需求,采集所有相关的环境要素与目标要素数据,主要模式为可见光图像。采集范围应覆盖:

- a) 杆塔本体结构:包括塔材、塔腿、横担、螺栓、塔基及接地装置等;
- b) 导线及其附属金具:包括导线、地线、绝缘子串、耐张线夹、悬垂线夹、防振锤、间隔棒、均压环、屏蔽环等;
- c) 通道环境:包括植被、树木、道路、建筑物、水体、山地等可能影响线路运行的物体;
- d) 风险源:包括跨越物、违章施工点、外力破坏隐患点等;
- e) 气象适应性:应涵盖不同气象条件下的图像,包括大雾、雨雪、逆光、强光及暗光环境,以确保模型在复杂工况下的泛化能力。

6.1.2 图像质量指标

用于零样本缺陷检测训练的巡检图像应满足以下基本质量要求:

- a) 分辨率:图像短边分辨率不宜低于 1080 像素,关键部件(如绝缘子、金具)在图像中的像素占比不宜低于 5%;
- b) 清晰度:图像应无明显运动模糊,拉普拉斯方差(Laplacian Variance)值宜大于 100;
- c) 曝光度:图像平均亮度宜在 50~200 之间,无严重过曝或欠曝导致细节丢失;
- d) 完整性:目标部件应完整出现在画面中,遮挡率不宜超过 30%;
- e) 格式要求:原始图像宜采用 JPG 或 PNG 格式,色彩空间为 RGB,压缩比不宜过高以避免伪影干扰特征提取。

6.1.3 采集要求

设备巡检视觉类数据采集应遵循以下原则:

- a) 图像中目标的尺寸与姿态角度应具有充分多样性，涵盖设备部件的不同姿态变化、表计指针的多方向指示，以及作业人员的多种动作姿态；
- b) 空间位置关系宜覆盖目标移位、缺失、脱落、距离过近或共面等典型场景，确保采集数据能够反映设备的多种结构状态；
- c) 图像背景应保持丰富且具有代表性，能够覆盖电网设备巡视的典型环境，如输电通道沿线的城区、郊区、山地、河流等多类型背景；
- d) 干扰因素应充分纳入采集范围，包括背景干扰物体、镜头模糊、污渍附着等情况，同时光照条件应包含暗光、正常光照、过曝、逆光、大雾等多种拍摄环境，确保模型能够在复杂环境下保持鲁棒性；
- e) 其他相关采集要求可参照 T/CES 129—2022 执行。

6.2 设备巡检文本数据采集

6.2.1 采集范围

设备巡检文本类数据的采集范围应根据具体任务需求，覆盖反映设备运行状态、运维活动和管理规范的各类文本信息。采集内容宜包括但不限于台账信息、巡检报告、维护记录、故障日志、规章制度等文档，并可补充相关技术资料、操作指南、调度记录、告警信息以及其他与设备运行和巡检活动相关的文本资料，确保文本数据能够全面反映设备生命周期特征、运维行为轨迹及故障演变过程。

6.2.2 采集要求

设备巡检文本类数据采集应遵循以下要求：

- a) 文本内容应与电网设备运行、巡检、维护及管理活动具有直接关联，能够覆盖设备生命周期的关键环节，包括运行状态、巡检事件、缺陷描述、处置措施及风险提示等信息；
- b) 采集的文本类型宜保持多样化，应包含结构化与非结构化文本，如台账信息、巡检记录、维护报告、故障处理单、运维工单、操作票、调度记录、工作规程及管理制度等，以确保语义覆盖全面；
- c) 文本来源应确保真实性与权威性，优先采集来自调度系统、资产管理系统（AMS）、状态监测系统、运维管理平台（OMS）、企业文档库等正式系统的记录，避免采用未经核实的非正式文本；
- d) 文本内容应保持完整性，采集时应避免缺页、信息截断、内容丢失等情况，必要时应保留文档元信息，如时间戳、记录人、设备编号及所属区域等；
- e) 文本的语言形式宜覆盖正式文书语言与自然语言表达，包括专业术语、行业标准表述、现场口述式记录等，以确保模型能够适应多风格文本输入；
- f) 文本采集过程中应充分考虑可能存在的异常内容，如错别字、口语化描述、缩写、省略表述、不一致格式等，采集时不应进行过度人工修正，以保持原始场景特征；
- g) 对涉及敏感信息（如地理位置、设备编号、人员信息）的文本，应按照相关安全规范进行脱敏或标记，确保数据采集过程符合信息安全与隐私保护要求；
- h) 其他未尽要求应参照 GB/T 42755—2023 及相关电力行业规范执行。

6.3 公开数据采集

6.3.1 采集范围

公开数据采集应围绕零样本缺陷检测模型的图文语义建模需求开展，采集内容宜涵盖能够增强模型视觉语义理解能力、结构认知能力及跨领域泛化能力的的数据资源。公开数据范围宜包括但不限于以下几类信息：

- a) 具备普适性视觉语义的图像数据，如通用物体识别类数据集、包含纹理、结构、材料、表面状态等多样视觉属性的公开影像资源，可用于丰富模型的视觉表征空间；
- b) 具有场景迁移价值的工业类或设备类图像数据，包括机械设备、金属构件、结构部件、管线连接件、螺栓紧固件等，可为电网设备的结构特征建模提供辅助语义；
- c) 与电力设备特征具有类比关系的公开缺陷图像，如裂纹、腐蚀、锈蚀、变形、磨损、松动、脱落、错位等工业缺陷样本，用于支撑模型的零样本缺陷特征外推；

- d) 含有丰富描述词汇与结构语义的文本资源，如百科类知识库、技术类描述语料、设备构造说明、通用工业检修文档等，用于构建模型的图文对齐能力和语义推理能力；
- e) 电力行业相关但非涉密的公开资料，如公开论文、标准节选、教材描述、电力设备通用原理介绍等，用于增强模型对设备部件名称、功能关系和结构语义的理解。

6.3.2 采集要求

公开数据的采集应遵循零样本缺陷检测模型的语义建模需求，确保数据可用于增强跨场景、跨部件、跨缺陷的表达能力。采集要求如下：

- a) 公开数据应具备与电网设备巡检任务的语义相关性，可在设备形态、材质、结构模式、故障表现、部件组合或视觉特征上与电力设备建立迁移关系；
- b) 采集的数据应能够提升模型的图文对齐能力，文本信息宜包含结构描述、部件关系、损伤表现、材料特性等语义，有助于模型构建细粒度描述能力；
- c) 公开图像数据应覆盖多样的物体类别、复杂背景、丰富纹理、不同光照与视角等，以增强模型在识别未知缺陷时的底层特征泛化能力；
- d) 用于构建缺陷语义描述的公开数据宜包含丰富的缺陷文本描述，可涉及裂纹宽度、腐蚀程度、磨损位置、部件错位量等描述性信息，以支持模型的语义外推；
- e) 数据质量应符合视觉建模要求，应避免分辨率过低、严重模糊、错误标注、语义冲突或不完整信息，同时应保留必要的上下文语义；
- f) 采集公开数据时应关注版权与合规性，确保所使用的数据资源满足开放授权要求；
- g) 对于与电力设备关联度较低但具有强迁移价值的公开数据，可在专家审核后纳入样本池，如工业设备热成像、机械构件故障图像、金属损伤样本等；
- h) 其他未尽事项可参考 GB/T 42755—2023 及相关行业规范执行。

7 数据清洗

7.1 设备巡检视觉数据清洗

7.1.1 数据去重

设备巡检视觉数据在用于零样本缺陷检测模型训练前，应开展系统性的数据去重工作，以避免重复或高度相似图像对模型造成偏置。数据去重过程应基于以下规则：

- a) 图像内容特征进行比对，通过计算视觉特征向量的相似度（如余弦距离或欧氏距离）识别重复拍摄、连续连拍或因无人机悬停导致的大量相似图像；
- b) 应综合考虑关键目标区域、拍摄角度、光照条件和背景差异等因素，防止因背景相似而误删有效样本；
- c) 对于包含缺陷的图像，应特别避免将其误判为重复样本；
- d) 在存在多张相似图像时，宜优先保留清晰度高、目标呈现完整、缺陷特征可辨识度更强的样本；
- e) 对于连续拍摄的视频帧或连拍序列，可通过关键帧提取方式减少冗余数据。

去重过程应保留必要的处理记录，包括候选重复样本及相似度评分，以满足审核与溯源需求。其他相关流程可参照 T/CES 129—2022 执行。

7.1.2 过滤低质数据

设备巡检视觉数据在清洗过程中应对低质量图像进行有效过滤，以保证模型训练样本的清晰度与可用性。低质数据通常包括因对焦不准、运动抖动或设备振动导致的模糊图像，以及在极端光照条件下出现的过暗、过曝、逆光严重、对比度不足等图像。

清洗过程中应结合图像清晰度指标、亮度分布、噪声水平与结构性信息损失情况，对图像质量进行定量或半定量评估：

- a) 对于无法辨识设备结构、缺陷区域或关键部件的图像应予以删除或降级处理；
- b) 对于因光照异常但仍具备可辨识价值的图像，应根据任务需求审慎保留；
- c) 若图像存在镜头污渍、遮挡物、强眩光、明显噪点、严重压缩失真等问题，且影响模型对设备与缺陷的判别，应将其列为低质数据予以剔除；

- d) 清洗过程应确保在剔除低质样本的同时，不损害缺陷类别的覆盖度与场景多样性，以保证数据集质量与模型泛化能力。

7.2 设备巡检文本数据清洗

7.2.1 敏感内容脱敏

设备巡检文本数据在清洗过程中应对涉及敏感信息的内容进行严格脱敏处理，确保数据使用的安全性与合规性。文本中若包含设备编号、资产编码、线路名称、地理坐标、用户信息、工作人员姓名、联系方式、单位名称等可能导致隐私泄露或影响系统安全的信息，应采用掩码、删除、抽象化替换等方式进行处理，同时保持文本语义的完整性和可理解性。在脱敏过程中，应避免对关键技术语义、缺陷描述或运维记录造成误删或误改，确保脱敏后的文本仍可用于模型训练和语义建模。

7.2.2 无用内容剔除

清洗过程中应识别并剔除与巡检任务无关或对模型训练无实际价值的文本内容。无用内容主要包括空文本、乱码、重复记录、格式化模板残留、日志系统生成的无意义信息、缺失关键字段的记录、错误格式的文档或内容不完整的文本。对于包含大量无关描述、噪声符号、异常编码或与设备运行无关的业务内容的文本，应予以剔除或清理，以确保保留的数据能够准确反映设备状态、巡检事件和缺陷特征，提高模型训练效率。

7.2.3 文本一致性

为提升文本数据的可解析性与结构化程度，应在清洗过程中对文本的一致性进行规范化处理。由于巡检记录来源多样，可能存在术语不统一、符号混用、单位不一致、时间格式不规范、部件命名差异等问题，应通过建立标准术语表、字段映射规则或文本规范化策略对相关内容进行统一。例如，应统一设备部件的名称表达、缺陷类型的描述方式、日期与时间格式、量纲单位等，确保文本中关键语义在不同来源的数据中保持一致，从而增强模型在图文对齐、语义推理和知识抽取任务中的表现。

8 数据标注

8.1 视觉图像数据标注

视觉图像数据标注应根据巡检场景和零样本缺陷检测任务需求开展，确保标注信息能够准确反映设备部件、结构状态和缺陷特征。标注内容宜包含设备部件的类别、位置、边界框或分割区域、部件间的结构关系及缺陷类型等信息。对于缺陷样本，应明确标注缺陷的具体部位、形态特征及表现形式，以支持模型在不同部件和场景中的泛化能力。标注过程中应关注图像中多角度、多光照、多遮挡、多尺度等情况，对模糊、部分遮挡或视角不完整的目标应根据实际可辨识程度进行合理标注。对于复杂部件或多目标场景，应确保各目标实例的标注不重叠、不遗漏，并保持语义一致性。标注完成后应进行质量复核，包括类别正确性、位置精度、边界一致性及缺陷表述准确性，确保数据集满足模型训练的质量要求。

8.2 图文联合数据标注

图文联合数据标注应围绕图像内容与文本描述之间的语义关联展开，确保图文对齐信息可用于构建跨模态语义空间。文本标注应准确描述图像中的设备类别、部件属性、结构关系、场景环境以及缺陷表现，并保持术语规范、表达清晰、结构完整。在图像中出现的关键部件或缺陷对象，应在文本中有对应的语义描述，实现图文语义一一对应。对于零样本任务相关的语义扩展描述，如“部件缺失”“绝缘子破损”“金具松动”等，应采用统一的语义模板或规范词表，以提升模型的特征投影提取能力与语义推理能力。对于多目标、多事件或多部件关系场景，文本标注应包含目标间的逻辑关系及事件顺序，避免语义模糊或歧义。标注完成后宜开展图文一致性校验，确保图像内容与文本描述之间不存在缺漏、冲突或错误关联。

8.3 数据增广

8.3.1 视觉数据增广方式

数据增广应根据巡检场景复杂性及零样本检测模型的泛化需求开展，用于提升模型对不同光照、角度、尺度、遮挡、背景及噪声条件的鲁棒性。对于视觉图像，可采用亮度调节、对比度增强、模糊模拟、裁剪、旋转、仿射变换、遮挡模拟、噪声注入等方法，同时应确保不改变设备关键结构或破坏缺陷语义特征。

8.3.2 图文数据增广同步

对于图文联合数据，可通过同义替换、语义增强、模板生成等方式扩展文本表达形式，同时保持核心语义不变。增广生成的样本应保持图文一致性，避免图像变化与文本描述不匹配。对涉及缺陷的样本，增广方式应保持缺陷区域的可辨识性，不宜引入影响判断的伪影或扭曲。增广后的数据应进行质量检查，确保其与原始样本在语义上保持一致，并可用于模型训练、微调及鲁棒性评估。

9 模型预训练

模型预训练旨在构建面向零样本缺陷检测的通用语义表达能力。预训练过程通常从多模态数据（如图像、文本、结构描述等）出发，通过跨模态语义对齐和拓扑结构知识构建的方式为后续的缺陷检测任务提供零样本推理能力。各环节逻辑关系如图 2 所示。

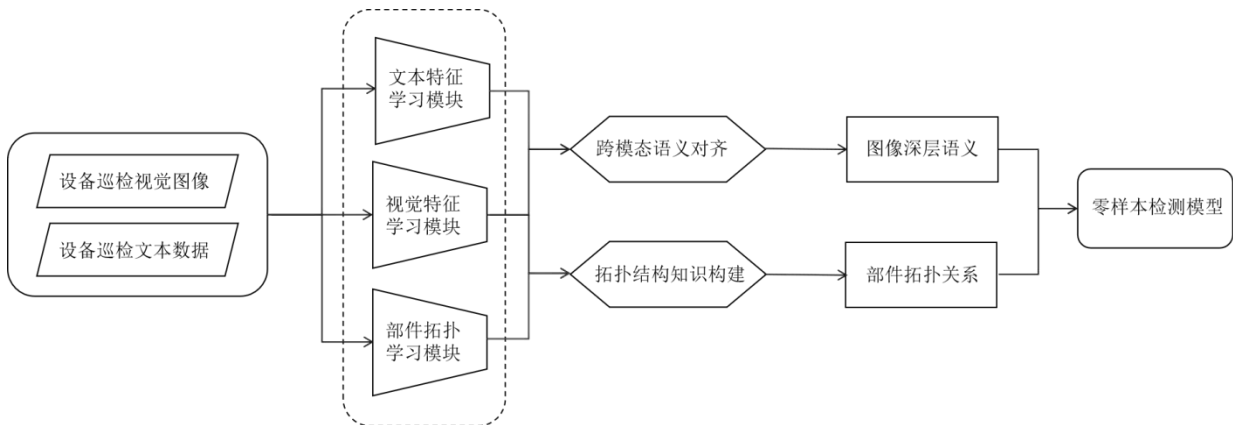


图2 零样本检测模型预训练流程图

9.1 图像深层语义表征能力要求

模型应具备多层次、多维度的视觉特征提取与编码能力，具体要求如下：

a) 多尺度特征融合能力：模型应能同时捕捉微观纹理细节（如绝缘子釉面裂纹、金具锈蚀斑点）与宏观结构特征（如塔材变形、导线断股形态）。应支持从像素级到对象级的特征金字塔构建，确保在不同拍摄距离和分辨率下均能保持特征完整性。

b) 复杂环境鲁棒性：预训练数据应覆盖全天候（昼/夜/黄昏）、全气象（雨/雪/雾/强光/逆光）及复杂背景（植被遮挡、建筑干扰）场景。模型应具备自适应去噪、光照归一化及背景抑制能力，在信噪比低于特定阈值时仍能提取有效特征。

c) 细粒度属性解耦：模型应能将设备的外观属性（颜色、材质、形状）与状态属性（完好、破损、异物）进行解耦表示。在面对未见缺陷时，应能通过组合已知属性特征，推理出新缺陷的视觉表现形式。

9.2 图文跨模态语义对齐要求

为实现“以文搜图”或“以文检缺”，模型必须建立高精度的图文映射关系：

a) 语义空间一致性：模型应将输电专业术语（如“自爆”、“销钉缺失”）的文本嵌入向量与对应的图像区域特征向量映射至同一高维空间。对于同义不同词的专业描述，模型应具备语义消歧与归一化能力。

b) 零样本泛化推理：模型应支持基于组合性描述的推理能力。当输入从未见过的缺陷描述时，模型应能利用已学习的结构知识和形态知识，自动合成检测逻辑，无需重新训练。

c) 上下文感知能力：模型应能理解文本描述中的空间关系（如“横担上方”、“绝缘子串底部”）及逻辑关系（如“伴随”、“导致”），并在图像中定位符合该上下文约束的目标区域，降低误报率。

9.3 部件拓扑结构与逻辑推理要求

9.3.1 三元组构建原则

模型应基于知识图谱技术，构建以“主体（Subject）- 关系（Relation）- 客体（Object）”为核心的拓扑三元组。

主体/客体：应为输电线路标准部件（如：绝缘子、均压环、销钉等）。

关系：应定义为物理连接、空间包含、功能依附等语义关系。

针对绝缘子串、金具串等复杂连接件，三元组提取必须通过以下逻辑校验，否则视为无效推理：

物理连接性校验：金具部件必须依附于绝缘子串或塔材主材，不得悬浮。

示例：(碗头挂板, 连接, 绝缘子钢帽) 为有效；(碗头挂板, 连接, 空气) 为无效。

序列完整性校验：对于串联组件（如绝缘子串），三元组应体现顺序逻辑。

示例：(第 N 片绝缘子, 邻接, 第 N+1 片绝缘子)。若检测到中间缺失导致逻辑断层，应触发“缺失”类零样本报警。

空间层级校验：小部件（如销钉、开口销）必须位于大部件（如挂板、联板）的孔洞或特定区域内。

示例：(开口销, 位于, 挂板销孔)。若检测到开口销位于挂板外部且无连接关系，应判定为“脱落”或“误检”。

9.3.2 复杂连接件的逻辑校验标准

针对输电设备结构固定、逻辑严密的特点，模型应显式地学习部件间的拓扑关系：

a) 层级化结构建模：模型应内置输电设备（杆塔、线路、金具、绝缘子等）的标准层级图谱。能够识别部件间的父子关系（如“铁塔”包含“横担”）、连接关系（如“挂点”连接“绝缘子”）及序列关系（如“均压环”位于“绝缘子”端部）。

b) 结构性异常检测：模型应具备基于拓扑规则的逻辑推理能力。不仅能识别部件本身的损坏，还应能识别“位置错误”（如销钉安装方向反）、“组件缺失”（如缺少防振锤）、“多余异物”（如鸟巢、飘浮物）等结构性缺陷，即使这些缺陷在训练集中未出现过。

c) 动态场景适应性：针对不同电压等级、不同厂家设备的结构差异，模型应具备小样本下的结构自适应能力，能够快速迁移并适配新的设备拓扑结构，避免因结构细微差异导致的漏检。

9.3.3 异常拓扑处理

当模型推理出的三元组违反上述校验标准时，系统应自动标记为“拓扑异常”，并作为零样本缺陷（如部件缺失、错位、异物挂载）的判据依据。

9.4 预训练数据与质量管控要求

输电线路导线舞动检测模型的预训练数据准备与质量管控应满足以下要求：

a) 数据多样性：预训练数据集应涵盖主要电压等级（35kV~1000kV）、各类典型杆塔型式及主流巡检设备（可见光、红外、紫外）采集的图像，样本量级应满足大模型训练需求。

b) 标注质量控制：用于预训练的图文对数据应经过专业校验，确保文本描述的准确性、完整性及与图像内容的高度匹配，噪声标签比例应控制在允许范围内（如<5%）。

c) 偏见消除：预训练过程应引入去偏机制，防止模型对特定背景、特定设备型号或特定拍摄角度产生过拟合，确保模型在分布外数据上的泛化性能。

10 模型迁移与微调

10.1 总体要求

模型微调旨在使预训练的零样本缺陷检测模型适配特定巡检任务场景，提高对电网设备、部件结构特征及场景语义的专门化理解能力。通过结合任务数据、场景特征和缺陷类型进行参数调整，增强模型的领域迁移能力与工程化表现。为确保微调任务能够覆盖真实电网场景需求，微调应满足以下要求：

a) 多源数据覆盖：微调数据集应全面覆盖架空输电线路的典型巡检场景，涵盖不同电压等级（110kV 至特高压）以及不同地形地貌（高山大岭、丘陵平原、跨江跨河），应整合图像、文本等模态信息，以提升模型在跨场景条件下的泛化能力；

b) 场景任务多样化：微调任务应覆盖不同设备类型、不同作业场景和不同业务需求，例如金具松动判别、绝缘子状态识别、杆塔结构完整性分析、站内安全隐患识别等，以增强模型的任务鲁棒性；

c) 语义一致性保障：微调数据中的设备部件名称、缺陷描述、作业动作术语等应保持一致，保证模型可在一致语义空间中学习任务逻辑；

d) 领域知识融合：微调过程中应结合电力安全规程、运维标准、设备结构知识与常见缺陷机理，通过提示词、结构模板或知识编码增强模型的领域推理能力；

e) 零样本友好：针对未知缺陷或新设备场景，可采用提示模板、语义扩展描述等方式减少微调数据依赖，确保在零数据条件下仍具备有效任务迁移能力。

10.2 差异化微调策略

模型应根据目标任务的数据规模、缺陷特征复杂度及场景差异度，选择适配的微调路径，确保模型能力与业务需求精准匹配。

a) 全维度特征适配策略

适用情形：针对具有极细微纹理特征的缺陷，或新型设备结构与既有知识库存在显著差异的场景。

实施要求：模型应支持对视觉特征提取与语义理解能力的全面更新与强化。微调过程应确保模型在掌握新设备细微特征的同时，保持对通用缺陷识别能力的稳定性，避免因新知识引入而导致原有识别性能下降。

b) 环境场景快速迁移策略

适用情形：针对同一类设备在不同地理环境（如高海拔覆冰区、沿海盐雾区、强风区）或不同成像条件（如夜间、逆光、雨雾）下的部署需求。

实施要求：模型应具备对环境背景噪声与成像风格变化的快速适应能力。微调应聚焦于提升模型在特定环境下的特征鲁棒性，消除因地域或气象差异导致的识别偏差，实现基于少量样本的场景化快速部署。

c) 专业知识逻辑增强策略

适用情形：针对金具组装顺序错误、部件缺失（如销钉、开口销）、异物挂载等高度依赖拓扑结构与先验知识的结构性缺陷检测任务。

实施要求：模型应将输电设备标准图谱、连接关系规则及运检规程融入推理过程。微调应强化模型对设备物理结构与逻辑规则的遵循能力，使其能够依据“应有而无”或“位置违例”等逻辑冲突进行缺陷判定，而非仅依赖外观相似度匹配。

11 模型零样本检测能力多维度能力评测

11.1 评测维度

模型零样本检测能力通过以下几个方面评估：

a) 跨部件与跨设备泛化能力：评估模型在未见过的部件、设备或场景上识别缺陷的能力。

b) 未知类别缺陷识别能力：评估模型对训练集中不存在的新缺陷类别的判断能力，包括相似特征捕获和异常模式识别能力。

c) 结构拓扑关系推理能力：评估模型基于部件空间位置、连接方式、组合结构判断缺失、错位、脱落或不合理组合等结构性缺陷的能力。

d) 图文语义对齐能力：评估图像特征与文本语义是否能在统一语义空间中准确对应，保障图文描述、图文问答和指令识别任务的稳定性。

e) 鲁棒性：评估模型在光照变化、模糊、遮挡、摄像角度变化、远距离拍摄等条件下的稳定性。

11.2 评测指标

11.2.1 准确性指标

准确性指标采用分层递进的设计理念，从图像级粗粒度判断逐步精细至像素级定位精度，全面覆盖零样本缺陷检测的全链路能力需求：

- a) 图像级异常判别能力：该能力考核模型对输入图像是否含有任何形式缺陷的二分类性能，采用准确率、精确率、召回率、F1 分数以及 ROC-AUC 作为核心评价指标，从整体分类正确性、假阳性抑制能力、假阴性控制能力以及阈值无关区分性能四个维度，对模型在图像级别的缺陷感知可靠性进行严格、客观的量化评估。
- b) 缺陷类别零样本语义识别能力：在确认图像存在缺陷的前提下，进一步考核模型对缺陷具体类别的零样本语义识别与匹配性能。该能力以 Top-K 准确率、Recall@K 以及图文匹配准确率为核心指标，依托多模态图文对齐机制，系统衡量模型对开放词汇缺陷描述的语义理解深度与类别区分精度，是评估 CLIP 架构模型及多模态大模型零样本语义推理能力的关键标准。其中强制性指标需要满足未知缺陷识别准确率应 $\geq 85\%$ ，关键缺陷误报率应 $\leq 10\%$ 。
- c) 缺陷区域空间定位精度：该能力针对模型输出的边界框或像素级掩码，考核其与真实缺陷区域的空间重叠程度与几何定位精确度。评价采用目标检测与实例分割领域的国际通用标准，包括平均精度均值（mAP，含 AP50、AP75 及 AP50:95）交并比（IoU）、像素级准确率以及平均交并比（mIoU），为开放词汇检测器及多模态分割模型的定位性能提供严谨、可比的量化依据。

11.2.2 零样本泛化能力指标

零样本泛化能力是评价模型在未见缺陷类别、开放词汇描述以及陌生工业场景下迁移性能的核心维度。依据通用零样本检测评测协议，该能力考核以零样本检测平均精度均值（ZSD-mAP）为首要指标，同时引入调和分数（H-Score）以衡量模型在已见类别与未见类别性能间的平衡性。此外，为适应开放环境，需辅以开放词汇检测召回率以及预测不确定性量化指标（如概率分布熵或最大软最大值倒数）。结合工业级无人机巡检的实时性与准确性需求，推荐性指标设定如下：零样本平均精度均值（ZSD-mAP）宜 ≥ 0.75 ，边缘侧设备推理时延宜 $\leq 200\text{ms}$ 。以上指标共同构成了具备鲁棒性与适应性的泛化能力评价标准。

11.2.3 结构推理能力指标

结构推理能力针对电力设备图像中复杂的部件拓扑结构与空间关系理解需求，重点考核模型是否具备高阶场景认知能力。该维度以 Recall@K (R@K) 为核心指标，衡量模型在置信度最高的前 K 个关系三元组中正确预测真实部件间关系的比例，并在给定真实对象框与标签、仅给定真实对象框以及全流程检测三种标准设置下分别报告；进一步引入 mean Recall@K (mR@K)，通过对每种关系类别单独计算 R@K 后取平均，有效解决电力设备中常见的长尾关系分布问题；同时采用零样本关系召回率（zero-shot Recall@K, zR@K），专门评估模型在训练阶段完全未见过的部件间关系（如新型连接方式或特殊空间布局）上的泛化能力。上述指标共同构成当前国际公认的最权威结构推理能力评价体系，能够全面、客观、严谨地量化模型对电力设备部件间拓扑与空间关系的理解水平，为复杂场景下的高阶认知能力提供可靠的评估依据。

11.3 评价数据集来源与构建规范

评测数据集的构建应遵循“严格隔离、来源多元、场景覆盖”的原则，确保评测结果的公正性与可验证性。

11.3.1 数据来源要求

评价数据集应包含真实业务场景数据：源自实际输电巡检业务（如无人机巡检、在线监测装置），涵盖不同电压等级（110kV~1000kV）、不同地形（山地、平原、跨江）、不同气象条件及不同设备厂商的图像与文本记录。此类数据占比不应低于 60%，以确保评测的工程实用性。

11.3.2 “已见”与“未见”集合划分规则

为严格验证零样本能力，必须构建互斥的训练集（已见集合，Seen Set）与测试集（未见集合，Unseen Set），“未知缺陷”的判定严格遵循数据集标签隔离原则，即只要某类缺陷的标签未出现在训练集标签体系中，即被划定为“未知”，该判定不依赖于模型的语义推理能力：

类别互斥性：测试集中的缺陷类别（如“均压环锈蚀”）或部件类别（如“新型防振锤”）严禁出现在训练集的标签体系中。两者在语义空间上应无直接重叠。

语义关联性：未见类别应与已见类别存在一定的语义关联（如同属“金属锈蚀”、“部件缺失”或具有相似的纹理结构），以验证模型的语义外推能力，而非随机猜测。

数据规模：每个未见类别的测试样本数不应少于 50 张有效图像，且需包含正负样本（含缺陷与正常），以确保统计显著性。

11.4 评测方法

11.4.1 推理阶段

推理阶段应在统一的环境配置下执行模型推理操作，确保评测过程的公平性与一致性。推理阶段应包括以下要求：

- a) 推理前应冻结模型参数，不得在评测过程中对模型进行训练、微调或权重更新，确保模型的零样本能力真实反映；
- b) 推理数据集应按“已见类别—未见类别”分组，模型应在不依赖未见类别样本的情况下执行检测、识别或推理，以验证真实零样本能力；
- c) 推理输入应保持原始数据的真实性，不得进行与实际巡检不符的过度预处理；涉及图像的缩放、裁剪等操作应保持比例一致，防止影响缺陷判断；
- d) 对于拓扑结构推理任务，应基于模型输出构建部件关系图或结构嵌入，并记录推理生成的拓扑关系结果；
- e) 推理过程中应记录模型的运行时延、吞吐量、显存占用等性能指标，以用于工程性能评估；
- f) 推理输出应以统一格式保存，包括检测框、类别标签、缺陷属性、部件关系、语义描述或图文相似度分值等，以便后续评分阶段读取与比对。

11.4.2 评分阶段

评分阶段应基于推理结果与标准标注数据进行对比，使用前述评测指标体系对模型性能进行量化评估。评分过程应遵循以下要求：

- a) 对缺陷检测类任务，应根据预测框与真实框的匹配情况，计算 mAP、ZSD-mAP、Recall、Precision 等指标；IoU 阈值应按任务需求统一设定，如 IoU=0.5 或 0.5:0.95；
- b) 对未见类别的零样本评测，应分别计算已见类别准确率与未见类别准确率，并利用 H-Score 衡量模型在泛化和保留能力之间的平衡；
- c) 对拓扑结构推理任务，应计算拓扑一致性评分（TCS）、部件关系准确率、结构异常识别率等指标，用于衡量模型对设备结构语义的理解深度；
- d) 对鲁棒性评测，应分别在清洁数据与扰动数据上独立计算性能指标，并统计性能衰减率，通过鲁棒性评分衡量模型对光照、模糊、遮挡等干扰因素的适应能力；
- e) 对性能评测，应使用推理阶段记录的延迟、吞吐量、算力消耗、显存占用等信息，计算工程性能指标，确保模型适合在电网实际环境中部署；
- f) 最终评分应形成统一评估报告，包含指标结果、典型案例、错误模式分析、未见类别识别情况与整体性能评分，用于模型质量验收与版本比较。

12 模型部署

12.1 计算环境与资源适配

12.1.1 异构算力兼容性

模型部署应支持主流异构计算架构，具备在云端服务器、边缘计算节点及前端采集终端等多种硬件环境下的适配能力。部署前应对目标平台的算力规模、存储容量、指令集架构及加速硬件接口进行兼容性评估，确保推理引擎能够充分利用底层硬件加速能力，并在不同算力层级间保持推理逻辑的一致性。

12.1.2 基础软件环境一致性

部署环境应确保操作系统、驱动程序、依赖库及推理运行时环境的版本兼容性与稳定性。对于跨平台部署场景，应建立标准化的环境配置规范，提供自动化环境检测与适配机制，消除因基础软件版本差异导致的运行异常，保障模型在不同系统环境下的可移植性。

12.2 安全与隐私保护体系

12.2.1 数据安全与访问控制

部署过程中应确保数据在存储、传输、处理和推理阶段的安全性，关键数据应采用加密存储和传输方式。在模型服务访问侧，应部署鉴权机制、访问令牌、权限分级等措施，防止数据越权访问，尤其在处理涉及地理位置、设备编号、运维记录等敏感数据时，应严格执行隐私保护规范。

12.2.2 模型安全与防护

部署的大模型可能面临对抗样本攻击、反向工程、参数盗取、越权调用等威胁，应采取模型加密、权重混淆、接口签名验证、防重放攻击与推理日志审计等措施。应建立部署环境安全基线，确保容器、服务端口及 API 不存在暴露风险。

12.2.3 电力生产环境部署安全要求

零样本缺陷检测模型若部署于电力监控系统安全区（如生产控制大区），必须严格遵循安全分区、网络专用、横向隔离、纵向认证的防护原则。严禁跨越安全区直接进行模型训练数据的实时传输。训练数据从生产控制大区向管理信息大区传输时，必须通过正向物理隔离装置进行单向导入，确保生产网数据不回流。规定模型推理服务接口应部署在安全接入区，并实施基于白名单的访问控制策略，禁止互联网直接访问

12.3 推理优化与性能提升

12.3.1 高并发与负载管理

模型推理应支持高并发访问场景，通过线程池、协程调度、多进程架构或服务实例扩展等方式提升吞吐量。对云端部署宜采用负载均衡、弹性伸缩、集群化部署等手段，实现服务高可用与故障转移。

12.3.2 模型压缩与量化优化

为提升推理速度、降低资源占用，应采用模型量化、蒸馏、剪枝、结构重排等技术，如 FP16、INT8、混合量化等方案。量化策略应结合硬件平台能力进行选取，并评估其对缺陷检测精度、拓扑识别能力及语义外推性能的影响。

12.3.3 推理框架与算子优化

应根据算力平台选择合适推理引擎（如 TensorRT、OpenVINO、MindIE、Ascend 端云框架等），并可通过算子融合、特定算子优化、内存复用、并行调度等方式进一步提升推理效率。对于场景固定的边缘端部署，可采用图优化、静态图构建与提前编译等方式缩短推理时间。

12.4 多环境部署与服务化架构

12.4.1 云边端协同部署

根据业务需求可采用云中心训练 + 边缘推理 + 终端采集的多级部署结构。云端负责复杂算法和大规模推理任务，边缘节点负责实时缺陷判断与数据筛选，无人机、巡检机器人等终端设备负责前端预处理。应确保三层协同过程的同步机制、数据一致性和断网可继续运行能力。

12.4.2 标准化封装与交付

模型交付应采用标准化封装格式，将模型文件、推理引擎、依赖环境及配置脚本集成于统一载体中，实现“一次构建，多处运行”。封装内容应包含完整性校验机制，确保交付物在传输与部署过程中未被篡改或损坏。

12.4.3 服务接口规范化

模型应以服务化方式提供能力，定义标准化的输入输出接口规范，支持与巡检管理系统、生产指挥平台等业务系统的无缝集成。服务接口应具备版本管理能力，支持灰度发布与平滑升级，确保业务系统调用的稳定性与兼容性。

12.5 生命周期管理与版本发布

部署时应建立规范化的版本管理机制，对不同模型版本、不同量化精度方案、不同设备适配方案进行可追踪管理。应提供版本切换能力，用以应对紧急回滚、快速升级或算法调优需求。

新增版本命名规范：规定模型版本号应采用 Major.Minor.Patch 格式（如 V1.2.3），其中 Major 代表架构重大变更，Minor 代表新增缺陷类别或场景适配，Patch 代表参数微调或 Bug 修复；

新增回滚机制：要求模型更新部署前必须进行测试，若新版本的零样本泛化能力（ZSD-mAP）或已知类检出率低于旧版本，应具备一键回滚至上一稳定版本的能力；

新增溯源档案：规定每个发布版本必须附带模型版本说明书，内容包括：训练数据版本、微调参数配置、适用场景范围、已知局限性、相比上一版本的性能增益/损耗对比报告；

新增兼容性要求：明确新版本模型应保持输入输出接口的向下兼容，确保上层业务系统无需改造即可接入。

12.6 部署阶段的安全与合规要求

模型在部署上线及运行过程中，除满足功能性能指标外，还必须满足以下人工智能应用规范与安全监管技术要求，以确保业务连续性与数据安全性：

- a) 已部署模型必须记录其核心特征提取器的版本、训练数据集的分布特征（如样本来源、缺陷类型覆盖率）及零样本泛化边界。每次版本更新需重新备案，以确保算法全生命周期的可追溯性与完整性校验；
- b) 对于未知缺陷（Zero-shot 类别），模型需输出“不确定性评分”，当评分高于设定阈值时，应自动归类为“疑似异常”并推送专家研判，而非强行分类；
- c) 部署端应具备对抗样本检测能力，防止因图像添加微小噪声导致模型误判（如将正常绝缘子识别为破损）；
- d) 建立模型运行效能监测看板，若某类缺陷的漏检率在连续 3 个月超过行业标准（如 5%），应自动触发模型回滚或停用机制，直至完成重新训练与验证。

13 标准的实施与维护

13.1 复审周期

鉴于零样本检测技术与大模型架构的快速演进特性，为确保本导则技术内容的先进性与适用性，建议本导则自发布之日起，每 3 年进行一次系统性复审。

13.2 临时修订机制

在复审周期内，若出现以下任一情况，应立即启动临时修订程序，不受 3 年周期限制：

- a) 国家发布新的人工智能相关法律法规、强制性标准或安全规范；
- b) 底层基础模型技术架构发生颠覆性变化，导致本导则规定的技术路线不再适用；
- c) 电力巡检业务场景中出现本导则未覆盖的重大新型缺陷模式或检测范式。

13.3 复审结论

复审结论为“继续有效”的，予以确认；复审结论为“修订”的，按修订程序执行；复审结论为“废止”的，由归口单位发布公告。新版本发布后，本版本自动废止。

附录 A

(资料性)

输电部件锈蚀缺陷零样本检测模型开发示例

A.1 输电部件锈蚀缺陷零样本检测任务设置

应规定输电部件锈蚀缺陷零样本检测任务的任务类型、目标部件、缺陷类别：

- a) 任务类型：图文多模态零样本缺陷检测，通过学习已知输电部件的锈蚀状态，识别未知部件的锈蚀状态，并正确识别；
- b) 目标部件：均压环，需确保模型在推理阶段之间未见过均压环；
- c) 缺陷类别：锈蚀，模型将通过联板、挂环等金具的锈蚀状态，推理出均压环的锈蚀状态；

A.2 输电部件锈蚀缺陷零样本检测任务数据采集

应根据任务选定要采集的数据范围以及数据形态：

- a) 数据范围：训练集需包含输电巡检场景除均压环以外常见部件的正常及锈蚀图像数据，测试集需包含正常及锈蚀状态的均压环数据；
- b) 数据来源：公开数据集及真实业务场景中符合要求的数据，数据量级需求低，每个部件的各类状态仅需 100 条左右，凸显零样本任务对数据量依赖性弱的特性；

A.3 输电部件锈蚀缺陷零样本检测任务数据清洗

数据采集完成后应对数据质量进一步审核，清洗掉画质低、熵值过高、显示异常、相似度过高的数据：

- a) 画质低/显示异常：图像中无法提取出可供分析的有效信息；
- b) 熵值过高：如背景过于杂乱的图像，过多无用信息干扰对目标区域的锁定和对有效特征的提取；
- c) 相似度过高：过于相似的图像会使模型反复学习相同的模式，加强对某种特性形式的偏见。

A.4 输电部件锈蚀缺陷零样本检测任务数据标注

根据章节 A.1 章节中的任务类型，用于训练及测试的数据都以图+文的形式呈现：

- a) 图像数据：应标注图像中所有输电部件的位置和大小目标框；
- b) 文字数据：对图像中每一个目标框做目标类型×部件状态（正常/锈蚀）二维标注。

A.5 输电部件锈蚀缺陷零样本检测模型预训练

冻结图像编码器部分，利用大模型在专业知识及通识上的海量知识预训练输电部件锈蚀缺陷零样本检测模型的文字编码器部分，完成专业知识迁移。

A.6 输电部件锈蚀缺陷零样本检测模型微调

解冻图像编码器后，根据任务目标做以下两方面微调：

- a) 利用标注后的训练集数据训练图像编码器，通过文字标签和图像目标框内特征的对齐，来实现图像—文字特征一致性的微调；
- b) 微调模型提示词，对缺陷类别“锈蚀”以及图像中的部件做进一步详细描述，达成特征迁移的微调目的。

A.7 输电部件锈蚀缺陷零样本检测模型评估

依照任务类型及任务边界设定，应采用准确性评测指标所包含的三类指标评估模型对缺陷类别及目标定位的推理能力，同时采用零样本泛化能力评测指标评估模型是否具备零样本检测方向的泛化能力。

附录 B
(资料性)
评测指标计算公式

B.1 准确性评测指标

B.1.1 图像级异常判别能力评测指标

B.1.1.1 准确率 (Accuracy)

表示模型对整张图像正确判断为“正常”或“存在缺陷”的总体比例，是衡量图像级缺陷有无判断能力最直观的综合指标。

计算公式如下：

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (\text{B.1.1.1})$$

式中：

TP —— 真阳性（正确判断为存在缺陷的缺陷图像数量）；

TN —— 真阴性（正确判断为正常的正常图像数量）；

FP —— 假阳性（误判为存在缺陷的正常图像数量）；

FN —— 假阴性（漏检的缺陷图像数量）。

B.1.1.2 精确率 (Precision)

在模型所有判断为“存在缺陷”的结果中，真正含有缺陷的比例，用于严格控制误报风险。

计算公式如下：

$$\text{Precision} = \frac{TP}{TP + FP} \quad (\text{B.1.1.2})$$

式中：

TP、FP 含义同 B.1.1.1。

B.1.1.3 召回率 (Recall)

在数据集中所有真实存在缺陷的图像中，被模型成功检测出来的比例，用于严格控制漏报风险。

计算公式如下：

$$\text{Recall} = \frac{TP}{TP + FN} \quad (\text{B.1.1.3})$$

式中：

TP、FN 含义同 B.1.1.1。

B.1.1.4 F1-Score

精确率与召回率的调和平均值，在正负样本分布不均衡时，作为图像级缺陷有无判断能力的综合评价指标。

计算公式如下：

$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (\text{B.1.1.4})$$

B.1.1.5 ROC-AUC

以假阳性率（FPR）为横轴、真正例率（TPR=Recall）为纵轴绘制 ROC 曲线后围成的面积，反映模型在所有可能阈值下的整体区分能力，取值范围为[0, 1]，数值越接近 1 表示区分能力越强。计算公式为曲线的积分形式，实际实现通常采用梯形法则或 Mann-Whitney 统计量。

B.1.2 缺陷类别零样本语义识别能力评测指标

B.1.2.1 Top-K 准确率（Top-K Accuracy）

模型输出的前 K 个最高概率缺陷类别中包含真实缺陷类别的样本比例，常用于评估开放词汇条件下的类别排序能力（常见值 K=1、5、10）。

计算公式如下：

$$\text{Top-K Accuracy} = \frac{1}{N} \sum_{i=1}^N I(y_i \in \text{top-K}(\hat{y}_i)) \quad (\text{B.1.2.1})$$

式中：

N —— 测试样本总数；

y_i —— 第 i 个样本的真实缺陷类别；

\hat{y}_i —— 模型对第 i 个样本的类别概率预测向量；

$\text{top-K}(\hat{y}_i)$ —— 取概率最高的前 K 个类别构成的集合；

$I(\cdot)$ —— 指示函数，条件满足时为 1，否则为 0。

B.1.2.2 Recall@K

在图像到文本或文本到图像检索任务中，模型返回的前 K 个结果中包含正确缺陷描述的比例，是衡量零样本语义匹配能力的核心指标。

计算公式如下：

$$\text{Recall@K} = \frac{\text{前 K 个结果中正确描述的数量}}{\text{该图像所有正确描述的总数（通常为 1）}} \quad (\text{B.1.2.2})$$

B.1.2.3 图文匹配准确率（Text-Image Matching Accuracy）

基于 CLIP 类模型的余弦相似度，统计正确缺陷描述与含缺陷图像的相似度高于错误/正常描述的样本比例。

计算公式如下：

$$\text{MatchAcc} = \frac{1}{N} \sum_{i=1}^N I(s(i, t_i^+) > s(i, t_i^-)) \quad (\text{B.1.2.3})$$

式中：

$s(i, t)$ —— 图像 i 与文本 t 的余弦相似度；

t_i^+ —— 与图像 i 对应的正确缺陷描述；

t_i^- —— 与图像 i 对应的错误或正常描述。

B.1.3 缺陷区域空间定位精度评测指标

B.1.3.1 平均精度均值 (mAP)

目标检测与开放词汇检测领域的国际通用指标。常规取用参数指标分别为 mAP@0.50、mAP@0.75 以及 mAP@0.50:0.95 (IoU 阈值从 0.50 到 0.95 平均)。

计算公式如下：

$$mAP = \frac{1}{|C|} \sum_{c \in C} AP_c \quad ; \quad AP_c = \int_0^1 p(r) dr \quad (B.1.3.1)$$

式中：

$|C|$ —— 测试集中缺陷类别数量；

AP_c —— 单个类别的平均精度；

$p(r)$ —— 以召回率 r 为横轴的精度-召回曲线。

B.1.3.2 交并比 (IoU)

单个预测边界框与真实缺陷区域的重叠程度，是判断检测框是否合格的基础阈值指标。

计算公式如下：

$$IoU = \frac{|B_p \cap B_{gt}|}{|B_p \cup B_{gt}|} \quad (B.1.3.2)$$

式中：

B_p —— 模型预测的缺陷边界框；

B_{gt} —— 人工标注的真实缺陷边界框。

B.1.3.3 平均交并比 (mIoU)

实例分割任务中所有类别 (含背景类) IoU 的平均值。

计算公式如下：

$$mIoU = \frac{1}{|C| + 1} \sum_{c=0}^{|C|} \frac{TP_c}{TP_c + FP_c + FN_c} \quad (B.1.3.3)$$

式中：

TP_c 、 FP_c 、 FN_c 分别为类别 c 的真阳性、假阳性、假阴性像素数。

B.2 零样本泛化能力评测指标

B.2.1 零样本检测平均精度均值 (Zero-Shot Detection mAP, ZSD-mAP)

在训练阶段完全未见过的缺陷类别上直接计算的 mAP，计算方式与 B.1.3.1 完全一致，区别仅为测试集类别与训练集无交集。

B.2.2 调和分数 (Harmonic Mean, H-Score)

衡量模型在已见缺陷类别与未见缺陷类别上性能的平衡程度，避免模型仅在已见类别上表现优异。

计算公式如下：

$$H-Score = 2 \times \frac{Acc_{seen} \times Acc_{unseen}}{Acc_{seen} + Acc_{unseen}} \quad (B.2.2)$$

式中：

Acc_{seen} —— 已见缺陷类别的准确率或 mAP;
 Acc_{unseen} —— 未见缺陷类别的准确率或 mAP。

B.2.3 预测不确定性熵

量化模型对输入图像类别预测的信心程度，熵值越高表示模型越不确定，常用于开放世界场景下的异常拒绝能力评估。

计算公式如下：

$$H(p) = - \sum_{i=1}^c p_i \log p_i \quad (B.2.3)$$

式中：

p_i 为模型输出的第 i 个类别的归一化概率。

B.3 结构推理能力评测指标

B.3.1 Recall@K

计算公式与 B.1.2.2 完全相同。在结构推理问题里，每张图像取模型置信度最高的前 K 个关系三元组，统计其中有多少比例是真正正确的关系，是目前场景图生成领域最核心、最通用的评价指标。

计算公式：

$$R@K = \frac{\text{top-K 预测中正确三元组的数量}}{\text{该图像中全部真实三元组的数量}} \quad (B.3.1)$$

式中：

top-K 预测中正确三元组的数量：模型输出的置信度排前 K 的三元组 < 主体 - 关系 - 客体 > 中，与标注完全一致且主体/客体框 $IoU \geq 0.5$ 的三元组个数；

该图像中全部真实三元组的数量：人工标注的所有有效关系三元组总数。

B.3.2 mean Recall@K (mR@K)

先对每一个关系类别单独计算 $R@K$ ，再对所有关系类别取平均，从而避免头部长尾关系主导整体分数，是结构推理方面解决类别不平衡的公认标准指标。

计算公式：

$$mR@K = \frac{1}{|\mathcal{R}|} \sum_{r \in \mathcal{R}} R_r@K \quad (B.3.2)$$

式中：

$|\mathcal{R}|$ —— 关系类别总数；

$R_r@K$ —— 仅在关系类别 r 上的 Recall@K。

B.3.3 Zeor Recall@K (zR@K)

在训练阶段从未出现过的关系类别上计算的 $R@K$ ，直接衡量模型对未见关系的泛化能力，是评估结构推理零样本性能的专用指标。

计算公式：

$$zR@K = \frac{1}{|\mathcal{R}_{unseen}|} \sum_{r \in \mathcal{R}_{unseen}} R_r@K \quad (B.3.3)$$

式中：

T/CES XXX—XXXX

$|\mathcal{R}_{unseen}|$ ——测试集中出现的、训练集中完全未见过的关系类别数量；
 $R_r@K$ ——仅在这些未见关系类别 r 上计算的 Recall@K

附录 C

(资料性)

电力设备部件拓扑关系分类、属性定义及建模参考

C.1 拓扑关系分类详表

应规定输电部件锈蚀缺陷零样本检测任务的任务类型、目标部件、缺陷类别：

表 1 拓扑关系分类表

关系大类	关系 ID	关系名称	定义描述	几何/语义约束条件	适用场景示例
物理连接	R-Phy-01	刚性连接	部件间无相对位移，物理接触	距离 $<5\text{px}$ ，角度偏差 $<5^\circ$	绝缘子与金具
	R-Phy-02	柔性连接	部件间通过线缆连接，存在弧度	存在连续像素连通域	引流线与线夹
空间关系	R-Spa-01	交叉跨越	两部件在图像平面投影相交	轮廓交集面积 $>$ 阈值	导线与树木/建筑
逻辑归属	R-Log-01	组件包含	A 是 B 的组成部分	A 的 bbox 完全在 B 的 bbox 内	销钉与金具

C.2 输电部件锈蚀缺陷零样本检测任务数据采集

节点向量 $V_i = \{\text{Class_ID}, \text{Conf}, [x_{\min}, y_{\min}, x_{\max}, y_{\max}], \theta, \text{Keypoints}\}$

边向量 $E_{ij} = \{\text{Rel_Type}, \text{Dist}_{\text{euclid}}, \text{Angle}_{\text{rel}}, \text{Conf}\}$,

式中 $\text{Dist}_{\text{euclid}}$ 为归一化后的中心点距离， $\text{Angle}_{\text{rel}}$ 为两部件主轴夹角。

C.3 典型设备标准拓扑模板（示例：悬垂串）

标准节点序列： $N_1(\text{挂点}) \rightarrow N_2(\text{U型环}) \rightarrow N_3(\text{首片绝缘子}) \dots \rightarrow N_k(\text{线夹})$

常见缺陷拓扑模式：

缺片：序列中断， N_i 与 N_{i+2} 直接相连，且距离异常增大。

自爆：节点 N_i 的纹理特征向量偏离标准分布，但拓扑连接保持。

异物：出现非标准节点 N_{unknown} ，且与 N_i 存在 $R - \text{Spa} - 01$ （交叉）关系。

C.4 拓扑图构建与推理流程建议

初筛：利用目标检测模型获取所有部件候选框。

几何建图：计算所有候选框对之间的距离和角度，构建全连接几何图。

语义剪枝：依据 C.1 中的约束条件，剔除不符合物理常识的边（如：绝缘子不可能直接连接塔材，中间必有金具）。

GNN 推理：将修剪后的图输入预训练 GNN 模型，输出节点分类和边分类概率。

规则校验：结合 C.3 的标准模板，识别拓扑结构异常。

附 录 D
(资料性)
电力专业语义模板库构建规范示例

D.1 总则

D.1.1 目的

为消除因自然语言描述差异导致的模型语义理解偏差，确保不同训练主体生成的多模态模型在“图像区域特征推理”和“部件拓扑关系推理”任务中具有统一的语义基准，特制定本模板库规范。

D.1.2 适用范围

本规范适用于所有基于本导则开发的输电巡检零样本缺陷检测模型，涵盖文本编码器输入提示（Prompt）的构造、缺陷类别定义及拓扑关系描述。

D.1.3 一致性原则

所有模板必须遵循“术语标准化、结构结构化、描述原子化”原则。严禁使用模糊形容词（如“有点坏”、“看起来不对”），必须使用本标准定义的专用术语。

D.2 术语与分类编码体

D.2.1 部件分类编码（Component Code）

采用层级化编码：[电压等级]-[线路类型]-[大类]-[子类]-[具体部件]。

示例：500kV-AC-TOWER-INSULATOR-CERAMIC（500kV 交流塔-绝缘子串-瓷绝缘子）

标准化要求：模型训练与推理时，部件名称必须映射到标准编码对应的中文标准术语。

D.2.2 适用范围缺陷类型编码（Defect Code）

采用“现象 + 程度”编码：[缺陷现象]-[严重程度]。

缺陷现象标准集：{锈蚀，裂纹，破损，缺失，松动，位移，放电痕迹，异物悬挂，鸟巢，植被逼近}。

严重程度标准集：{一般，严重，危急}。

示例：CRACK-SEVERE（严重裂纹）。

D.3 语义模板结构规范

所有语义模板由 [上下文前缀] + [主体描述] + [缺陷/状态描述] + [拓扑约束(可选)] 四部分组成。

D.3.1 基础缺陷检测模板（用于区域特征推理）

格式：一张输电线路巡检图像，图中显示{部件名称}存在{缺陷现象}，程度为{严重程度}。

负样本模板：一张输电线路巡检图像，图中显示{部件名称}状态正常，无{缺陷现象}。

示例：

正样本：一张输电线路巡检图像，图中显示瓷绝缘子存在破损，程度为严重。

负样本：一张输电线路巡检图像，图中显示瓷绝缘子状态正常，无破损。

D.3.2 拓扑关系推理模板（用于部件拓扑关系推理）

格式：一张输电线路巡检图像，图中{部件 A}与{部件 B}的连接关系为{关系描述}，当前状态为{异常类型}。

关系描述标准集：{连接，悬挂，支撑，包裹，相邻，位于...上方，位于...下方}。

异常类型标准集：{缺失，错装，位移，距离过近}。

示例：

缺失类：一张输电线路巡检图像，图中导线与防振锤的连接关系为悬挂，当前状态为防振锤缺失。

位移类：一张输电线路巡检图像，图中均压环与绝缘子串的连接关系为安装于端部，当前状态为均压环位移至中部。

D.4 提示词工程（Prompt Engineering）标准化策略

为确保零样本推理的鲁棒性，模板库需包含以下三种变体，训练时应随机采样或组合使用：

D.4.1 简单描述型（Simple）

直接陈述事实。

模板：{部件} {缺陷}。

例：绝缘子自爆。

D.4.2 详细场景型（Detailed Context）

增加环境背景描述，模拟人工巡检报告语气。

模板：在高压输电线路巡检场景中，观察{部件}出现了明显的{缺陷}，这属于{严重程度}缺陷。

例：在高压输电线路巡检场景中，观察到金具出现了明显的锈蚀，这属于一般缺陷。

D.4.3 结构化问答型（Structured QA）

强化逻辑推理能力。

模板：问题：图中的{部件}是否存在{缺陷}？回答：是，检测到{缺陷}，位置在{相对位置}。

例：问题：图中的导线是否存在异物悬挂？回答：是，检测到异物悬挂，位置在导线跨中。

D.5 模板库管理与扩展机制

D.5.1 版本控制

模板库实行版本化管理（如 V1.0, V1.1）。任何新增的缺陷类型或部件，必须先更新术语表，再生成对应模板，严禁私自造词。

D.5.2 拓扑关系推理模板（用于部件拓扑关系推理）

为解决自然语言的多样性，建立标准术语到常见同义词的映射，但在输入模型核心训练时，必须统一转换为标准术语。

映射示例：

输入：生锈，腐蚀，锈迹 -> 标准化：锈蚀

输入：断了，裂了，破碎 -> 标准化：破损 或 裂纹（视具体形态定）

输入：没了，掉了 -> 标准化：缺失

附录 E

(资料性)

架空线路零样本缺陷检测成功案例

E.1 案例一：基于视觉语言模型与双专家模块的输电线路零样本检测

E.1.1 案例背景

在输电线路无人机巡检中，绝缘子破损、导线断股等缺陷样本获取困难，且背景复杂多变。传统深度学习模型受限于封闭集识别，难以泛化到未见过的缺陷类型，导致漏检率高。

E.1.2 技术方案

核心架构：采用先进的视觉语言模型架构，利用其在海量图文对数据上预训练获得的强大先验知识。

双专家机制：引入专门设计的“双专家模块”。该模块包含视觉专家和语言专家两个分支：视觉专家负责提取图像中目标的细粒度特征；语言专家则根据缺陷的语义描述（如“伞裙断裂”、“金具锈蚀”）提取对应的文本特征。

零样本推理：通过计算图像特征与文本特征的相似度进行分类，而非传统的 Softmax 分类。当遇到未见过的缺陷类型时，只需修改文本提示（Prompt），模型即可实现对该缺陷的识别，无需重新训练网络参数。

E.1.3 实施效果

该方案在公开电力设备数据集上验证，成功实现了对未见过缺陷类别的零样本识别。相比传统方法，像素级缺陷分割性能（AUROC）平均提升 18.1%，F1-max 分数平均提升 26.1%。该案例证明了利用文本语义引导视觉检测在解决“长尾缺陷”识别难题上的有效性。

E.2 案例二：基于工业视觉大模型 AnomalyGPT 的通用零样本检测

E.2.1 案例背景

在电力设备通用外观巡检中，面对海量的设备类型和未知的异常形态，传统算法需要针对每种设备单独收集数据并训练模型，开发周期长、成本高。亟需一种通用的零样本检测方案。

E.2.2 技术方案

核心架构：采基于工业视觉大模型 AnomalyGPT，该模型基于大规模预训练的视觉-语言模型构建。

异常感知微调：设计特定的异常感知指令微调（Instruction Tuning），让模型具备理解“什么是异常”的通用常识。

人机交互检测：支持通过自然语言指令（如“检测设备是否破损或锈蚀”）直接引导模型识别异常，实现“以文搜图”。

E.2.3 实施效果

AnomalyGPT 在权威工业缺陷检测数据集上取得了业内先进的性能，在电力设备巡检场景中，该模型无需任何训练数据即可直接部署，显著降低了模型开发和迭代成本，证明了通用大模型在跨场景、跨类别缺陷检测中的广阔应用前景。