



基于语义信息距离解耦的变电运维多类别缺陷图像检测

张鑫^{1,2}, 叶俊杰³, 崔瑶^{1,2}, 黄鑫^{1,2}, 仲林林³

(1. 南瑞集团有限公司(国网电力科学研究院有限公司), 江苏南京 211106; 2. 智能电网保护和运行控制国家重点实验室, 江苏南京 211106; 3. 东南大学电气工程学院, 江苏南京 210096)

摘要: 变电站设备种类繁多、缺陷类型复杂、特征差异大, 传统的基于深度学习的缺陷图像检测模型难以同时有效处理不同设备的多种缺陷。为此, 提出了一种基于语义信息距离解耦的缺陷图像检测模型 (semantic-distance based decoupling detection model, SDB-DDM)。首先对缺陷类别进行语义信息聚簇, 构建解耦式网络结构, 然后对网络输出进行加权锚框融合, 并在损失函数中加入局部预测损失以提升预测能力, 同时提出解耦式非极大值抑制策略以加快模型推理速度。该模型可根据缺陷类别进行自适应调整, 以适用变电运维多类别缺陷图像检测的应用场景。实验结果显示, 该模型的平均精度均值达到了 69.68%。同平台下相较于目前性能最佳的目标检测模型 (YOLOX), 精度提升了 1.36 个百分点, 参数量下降了 5%, 推理速度提升了 34%。

关键词: 变电运维场景; 缺陷检测; 深度学习; 语义信息距离; 解耦式模型

DOI: 10.11930/j.issn.1004-9649.202208117

0 引言

变电站是电力系统的能量枢纽, 其内部设备种类繁多, 潜在缺陷复杂多样^[1-2], 需要及时有效的运维管理, 以保障电力系统的安全稳定运行^[3-4]。随着人工智能技术的发展, 越来越多的图像视频采集设备被投入到变电站日常运维中, 收集变电运维场景中的缺陷图像并训练基于深度学习的缺陷图像检测模型已成为提升变电站智能化运维水平的重要手段^[5-6]。文献[7]研究了基于改进型单阶段检测模型 (single stage detection, SSD) 的绝缘子红外缺陷图像检测模型, 并通过实验证明其有效性。文献[8]基于径向基概率神经网络, 融合传统模式识别算法, 实现了对复杂背景图像中线路的快速分割与缺陷检测。文献[9]采用焦点损失检测模型 (RetinaNet) 实现了对架空线路中销钉缺陷的检测, 并着重考虑了对于销钉缺陷正

负样本不均衡问题的解决方案。文献[10]使用 3 组关键点目标检测模型 (CenterNet) 并结合结构化定位, 实现了复杂红外图像中变压器过热缺陷的有效检测。文献[11]使用 SSD 检测监控图像中的主变压器位置, 并训练卷积神经网络用于识别主变压器的外观缺陷。文献[12]通过对传统目标检测的特征金字塔网络进行改良, 并引入可变卷积实现了绝缘子缺陷的有效检测。

上述方法均是采用深度学习模型检测特定类型的缺陷, 而变电站中复杂多样的缺陷类型要求深度学习模型具备多类别缺陷的检测能力。文献[13]将加速区域卷积神经网络 (faster region-convolutional neural network, Faster-RCNN)、第三代单阶段端到端目标检测模型 (you only look once version3, YOLOv3)、掩码区域卷积神经网络 (mask convolutional neural network, Mask R-CNN) 进行组合, 训练组合式模型以预测杆塔和绝缘子故障, 相较于传统模型在精度上有了很大提升。文献[14]使用改进型 YOLOv3 级联式分类网络, 将缺陷检测过程分解为设备定位和设备状态判定, 实现了绝缘子、螺栓和线路缺陷的检测。文

收稿日期: 2022-08-30; **修回日期:** 2022-11-18。

基金项目: 国网电力科学研究院有限公司科技项目 (5246 06210002)。

文献 [15] 通过在 Faster RCNN 中添加特征金字塔网络, 对损失函数和非极大值抑制 (non maximum suppression, NMS) 进行适当调整, 实现了变电站中常见缺陷的有效检测。文献 [16] 采用改进型卷积神经网络结合模式识别策略, 对变电设备红外图像中的电流互感器、隔离开关、避雷器等 7 类设备缺陷进行了检测。文献 [17] 采用改进型 SSD 网络识别变电设备, 并利用对抗生成网络提升模型的缺陷检测能力, 实现了电压互感器、表盘、柜门、绝缘子等多类缺陷的有效检测。

现有的缺陷图像检测模型大多用于处理变电运维场景下单类缺陷或数个语义信息较为接近的缺陷类别, 对计算、存储等硬件资源需求高。然而, 在变电站智能运维场景下, 潜在缺陷包括设备损坏、人员违规、异物入侵等语义信息差异较大的缺陷类别, 现有模型在上述场景中缺乏对这种多类别缺陷的综合处理能力, 难以满足灵活可靠部署的需求。这是由于传统目标检测方法在训练模型时忽略了标签间真实存在的语义信息距离差异, 将其强行拟合为独立分布, 无形中增加了网络的计算和存储成本。随着数据集类别的增加, 这种强行拟合会带来显著的资源消耗。而在变电运维场景中, 这一问题会更加严重。一方面, 变电运维场景中潜在类型多样且影响深远, 需要对其进行全局监管; 另一方面, 这些潜在缺陷由于发生场景不同, 呈现语义信息距离的显著差异 (例如表盘模糊与表计读数损坏语义信息接近, 与绝缘子破裂信息相去甚远)。

综上, 本文提出一种基于语义信息距离解耦的缺陷图像检测模型 (semantic distance based decoupling detection model, SDB-DDM), 以实现对变电运维多类型缺陷的灵活检测。首先针对变电站潜在缺陷复杂繁多的问题提出一种面向变电运维场景缺陷的自适应分组策略, 然后根据分组结

果搭建模型, 并结合网络结构特征, 提出面向训练阶段的模型性能提升策略和面向模型推理阶段模型推理加速策略。实验结果显示, 本文所提模型架构灵活, 相对于主流模型, 在具备近似检测精度的同时, 显著降低了模型的参数量和推理时间。

1 SDB-DDM 网络模型

在充分考虑变电运维缺陷检测场景特征的基础上, 将缺陷类别按照语义信息距离聚集为若干簇, 提出基于语义信息距离解耦的缺陷图像检测模型 SDB-DDM, 使用多个子网络分别检测不同簇内的缺陷类别。SDB-DDM 整体架构如图 1 所示, 具体的实现过程主要包括以下 5 个步骤。

1) 构建变电运维场景下多类别缺陷图像数据集, 训练跨阶段局部连接网络 (cross stage partial darkNet, CSPDarkNet) 分类网络。

2) 从不同缺陷类别中抽取同数量的缺陷图像, 构成评估集并输入到训练好的 CSPDarkNet 中, 获得具有不同网络深度的特征图, 并生成对应的空间金字塔池化 (spatial pyramid pooling, SPP) 向量, 在此基础上构建评估函数以确定解耦位置, 并对 SPP 向量聚簇以确定各簇内的缺陷类别组成。

3) 根据解耦位置和聚簇策略, 搭建 SDB-DDM 网络, 其前端网络通过公共特征提取网络对图像的浅层信息进行筛选, 后端网络根据聚簇结果搭建若干解耦子网络负责各簇缺陷的特征融合。

4) 为解决解耦式子网络中正负样本不均衡的问题, 对子网络的输出应用加权锚框融合 (weighted anchor fusion, WAF) 策略形成全类别预测向量, 并搭配简化型最优传输分配 (simplified optimal transport assignment, SimOTA) 策略选取正负样本以计算全局损失 [18]。同时, 在损失函数中加入局




图 1 SDB-DDM 整体架构

Fig. 1 Architecture of SDB-DDM



部预测损失 (local prediction loss, LPL), 进一步提升子网络的预测能力。

5) 在推理过程中, 为了节约推理时间, 采用解耦式非极大值抑制策略 (decoupled non maximum

suppression, D-NMS) 加快边框抑制以减少计算量。

SDB-DDM 的网络结构如图 2 所示, 网络参数如表 1 所示。

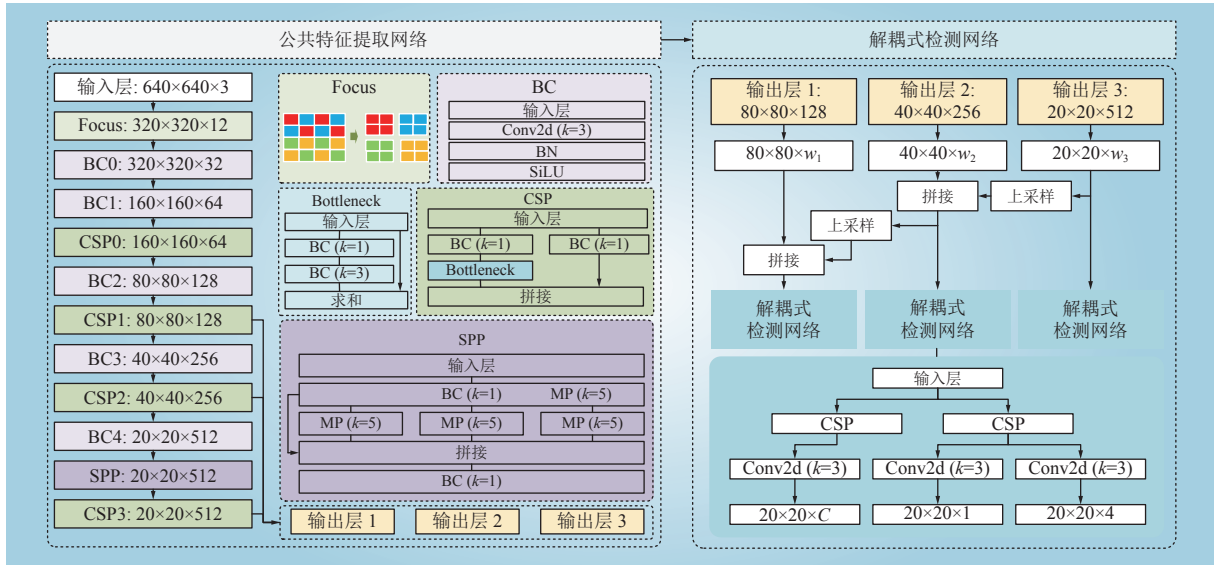


图 2 SDB-DDM 网络结构
Fig. 2 Structure of SDB-DDM

表 1 SDB-DDM 网络参数
Table 1 Parameters of SDB-DDM

网络	层	具体说明	备注
公共特征提取网络	Focus		
	BaseConv (BC)	Conv2d+BN+SiLU	卷积核(k)尺寸为3时, 步长为2, 填充尺寸为「(k-s)×0.5」 卷积核(k)尺寸为1时, 步长为1, 无填充
	Maxpooling (MP)	Maxpooling2d	默认池化尺寸(k)为3, 步长为1, 填充尺寸为「(k-s)×0.5」
	Concat	$w \times h \times c_1 + w \times h \times c_1 \rightarrow w \times h \times (c_1 + c_2)$	
解耦式检测网络 (以一簇为例)	上采样层		默认上采样比例为2, 填充模式为就近填充
	BaseConv (BC)	Conv2d+BN+SiLU	卷积核(k)尺寸为3, 步长为1, 填充尺寸为「(k-s)×0.5」
	Concat	$w \times h \times c_1 + w \times h \times (c_1 + c_2)$	

公共特征提取网络: 考虑到变电运维场景中不同类别缺陷图像的浅层特征较为相近, 基于 CSPDarkNet^[19-20] 搭建了公共特征提取网络, 参见图 2。

解耦式检测网络: 根据步骤 2) 的聚簇结果,

结合各簇内缺陷类别数在总类别数中的占比, 将公共特征提取网络输出的特征图按照通道数切分为若干子特征图。将其输入到解耦式子网络中对特征信息进行筛选和融合, 并最终输出尺寸为 $(80 | 40 | 20) \times (80 | 40 | 20) \times 1$ 、 $(80 | 40 | 20) \times (80 | 40 | 20) \times 4$ 、 $(80 | 40 | 20) \times (80 | 40 | 20) \times C$ (C 为类别数) 的簇内目标置信度、边框回归、簇内缺陷类别预测向量, 非簇内缺陷在该网络学习过程中被视为背景。以 $80 \times 80 \times *$ 的预测向量为例, 由于卷积操作的空间不变性, 每个预测向量即对应了原图中尺寸为 $8 \times 8 \times 3$ 的局部区域, 将其称为锚框, 解耦式子网络输出的目标置信度、边框回归、簇内缺陷类别预测向量分别表示该锚框包含目标的可能性、包含目标时边框回归参数以及目标属于簇内各类缺陷的概率^[21]。

2 基于 SDB-DDM 的变电运维场景多类别缺陷图像检测

2.1 基于语义信息距离的缺陷类别聚簇

考虑到变电运维场景下缺陷种类众多, 且不

同缺陷类别间语义信息距离差异性较大，同类设备上不同缺陷间的语义信息距离显著小于不同设备不同缺陷间语义信息距离。本文基于图像语义

信息距离对变电运维场景下缺陷图像类别进行聚簇，即将语义信息相近的缺陷类别归为同一组，称为簇。具体算法步骤如图 3 所示。

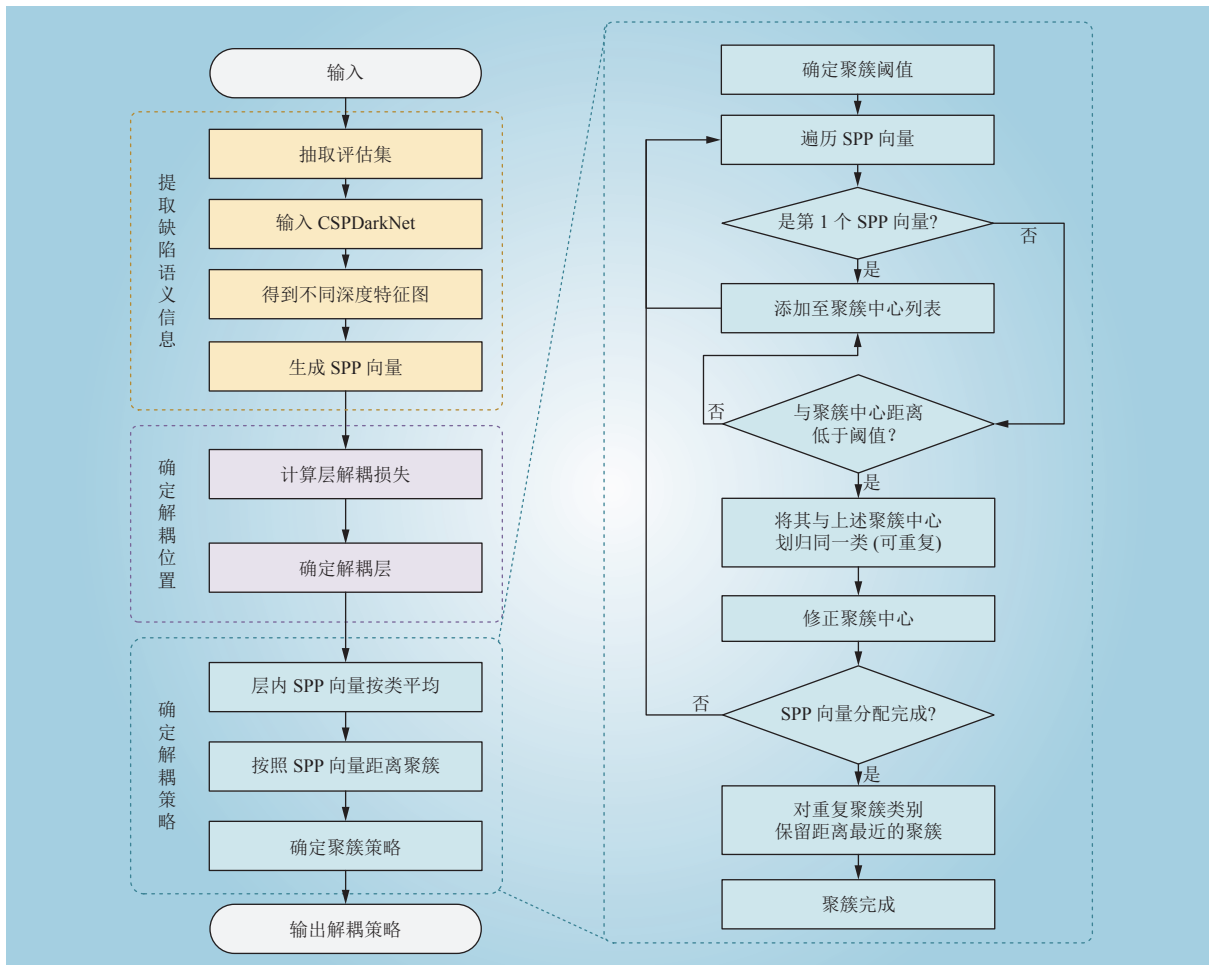


图 3 基于语义信息距离的缺陷类别聚簇

Fig. 3 Clustering of defect classes base on semantic information distance

1) 按照缺陷类别随机抽取同数量的缺陷图像构成评估集，若单张图像中有多类缺陷可重复抽取，否则仅可抽取 1 次，每类缺陷的图像数量在 150~200 张为宜^[22]。

2) 将评估集输入到前期训练好的 CSPDarkNet 中，提取具有不同网络深度的特征图，并生成对应的空间金字塔池化 SPP 向量。SPP 向量^[23]起初是用于将不同尺寸的特征图转为固定尺寸的特征向量，而后多用于提取特征图中的语义信息，弱化或滤除特征图中的目标尺寸、目标位置信息。SPP 向量的生成步骤如图 4 所示，在输入尺寸为 $w \times h \times c$ 的特征图后，将其分别输入到全局最大值池化层和区域最大值池化层，然后将输出张量按

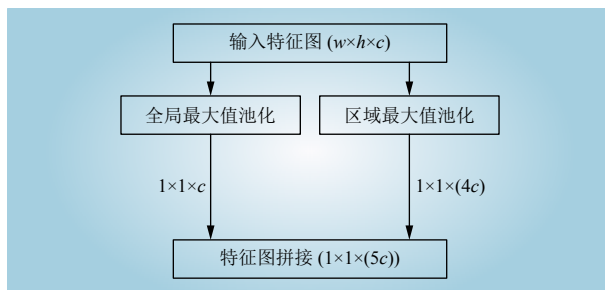


图 4 SPP 向量生成过程

Fig. 4 Process of generating SPP vectors

照通道数拼接，得到特征图的 SPP 向量。

3) 构建评估指标 f_{eval} 以量化不同深度的局部网络对多类别缺陷图像的语义区分能力，从而选



出具有最优语义信息区分能力的公共特征提取网络结构。 f_{eval} 的计算式为

$$\begin{cases} f_{\text{eval}} = \sum_{i=1}^n \frac{d_e^i}{d_o^i} \\ d_e^i = \sum_{j=1}^n (X_{ij} - \bar{X}_i)^2 \\ d_o^i = \sum_{\substack{k=1 \\ k \neq i}}^n \sum_{j=1}^n (X_{kj} - \bar{X}_i)^2 \end{cases} \quad (1)$$

式中： d_e^i 为同类缺陷所对应 SPP 向量间的欧几里得范数； d_o^i 为异类缺陷所对应 SPP 向量间的欧几里得范数； c 为缺陷类别数； n 为每类缺陷对应的图像数； i 、 k 为类别序号； j 为单类缺陷中图像序号； X_{ij} 为第 i 类缺陷中第 j 张图像对应的 SPP 向量； \bar{X}_i 为第 i 类缺陷对应 SPP 向量组的中心向量。

考虑到同类缺陷的图像语义信息距离应较小，对于多类别缺陷图像语义区分能力越强的网络，其对应 f_{eval} 的越小。

4) 确定解耦层后，将层中的 SPP 向量按缺陷类别求均值，得到各类缺陷的 SPP 中心向量。计算典型 SPP 向量距离均值作为聚簇阈值。创建空列表，放入第 1 个 SPP 向量，将其作为此列表的初始中心向量。

5) 依次遍历剩余 SPP 中心向量并执行后续操作直到遍历完成。计算当前 SPP 中心向量与各个列表中心向量的距离；若距离低于聚簇阈值，则将其放入符合要求的列表中，并重新计算列表中 SPP 中心向量的均值作为新的列表中心向量；若与所有列表中心向量距离均高于阈值，则创建空列表，将此 SPP 中心向量放入新创建的列表中。

6) 若出现同时存在于多个列表中的 SPP 中心向量，则计算此 SPP 中心向量与其所在各个列表中心向量的距离，保留计算结果最小的列表内的 SPP 中心向量，其余列表中的重复向量均舍去。若不存在上述情况，此步跳过。

执行完上述步骤后，同一个列表中的 SPP 向量对应的缺陷类别归为一簇，列表数即聚簇数。

2.2 闭合式训练策略

根据聚簇结果，按照图 2 所示的方式完成解耦式检测网络的搭建。其中，各个解耦式子网络将输出每个预测向量所对应的锚框中包含目标的置信度、边框回归以及目标归属于簇内各个缺陷

的概率。实测中发现，由于后端网络的解耦，分配给各个子网络检测的目标非常稀少，造成了正负样本的严重失衡，影响了模型的检测精度。因此，提出闭合式训练策略如图 5 所示。将各簇的预测结果按照其对应的锚框，整合为对所有缺陷位置和类别进行预测的向量。




图 5 闭合式训练策略

Fig. 5 Closed training strategy

对整合后的预测向量使用 SimOTA^[14] 进行正负锚框匹配，而后对置信度和类别预测向量计算交叉熵损失，对位置预测向量计算 Ciou 损失^[17]，得到模型训练的全局损失。

在进行闭合式训练时，为了提升模型整体预测精度并保证子网络的预测准确率，本文提出加权锚框融合策略和局部预测损失约束。

1) 加权锚框融合。每个子网络的输出向量可分为 3 个部分，分别表示其对应锚框中包含目标的置信度、锚框与真实框的修正向量以及目标归属于簇内各缺陷的概率。在执行闭合式训练时，将各个子网络的检测结果整合为对所有缺陷的预测向量。

在整合过程中，对于每个子网络的类别预测向量，将子网络的特征图按照对应锚框进行拼接，对拼接后的向量进行多类别逻辑回归函数 Softmax 操作，得到锚框内包含各类缺陷的概率分布。对子网络的置信度和位置预测向量进行加权融合，其计算公式为

$$\begin{cases} C = \left(\sum_{i=1}^n w_i C_i \right) / \left(\sum_{i=1}^n w_i \right) \\ B = \left(\sum_{i=1}^n w_i B_i \right) / \left(\sum_{i=1}^n w_i \right) \\ w_i = \sqrt{\frac{n_i}{N}} \end{cases} \quad (2)$$

式中： C_i 为第 i 个子网络预测的置信度向量； B_i 为第 i 个子网络预测的边框向量； n_i 为第 i 个子

网络负责的缺陷类别数； N 为总类别数； C 、 B 分别为整合后的置信度、位置预测向量； w_i 为加权锚框融合策略中的加权系数。

2) 局部精度损失约束。在执行闭合式训练时，仅对整合后的网络计算损失无法保证子网络预测结果的准确性。考虑到子网络输出向量中，簇内缺陷类别预测向量已经整合到全局预测向量中，位置向量的采纳与否取决于置信度的高低。因此，提升子网络预测能力的核心在于保证子网络置信度预测向量的准确性。故本文提出局部预测损失 LPL，其工作过程如图 6 所示。




图 6 局部精度损失
Fig. 6 Local precision loss

将真实标签按照聚簇结果转为各个子网络的置信度标签，即每个预测向量对应的锚框中是否包含目标。根据子网络输出结果，计算交叉熵损失^[17]作为局部损失以约束子网络的置信度预测结果，从而提升子网络的缺陷检测能力。将局部损失与全局损失加权融合后，作为模型训练过程中的综合损失函数。

2.3 解耦式模型推理策略

完成模型训练后，在推理阶段需要将子网络的输出结果转换为带有类别和置信度信息的预测框，再对模型进行非极大值抑制 NMS^[24]后滤除冗余的预测框。考虑到所提模型结构的特殊性以及在现实应用场景下模型输入图像中目标数量较为稀少的特点，在推理阶段提出解耦式非极大值抑制 D-NMS，其主要流程如图 7 所示。

在完成模型推理后，遍历子网络的输出向量，计算其置信度的最大值是否高于 0.5。若当前子网络所有预测向量的置信度均低于 0.5，则继续读取下一个子网络的输出结果；否则，将子网络中置信度高于 0.5 的预测向量还原为带有缺陷类别信息的预测框，并对这些预测框执行传统的 NMS。由于不同子网络负责的缺陷类型不同，不同子网络的预测框不可能存在同类缺陷交并比高于阈值的

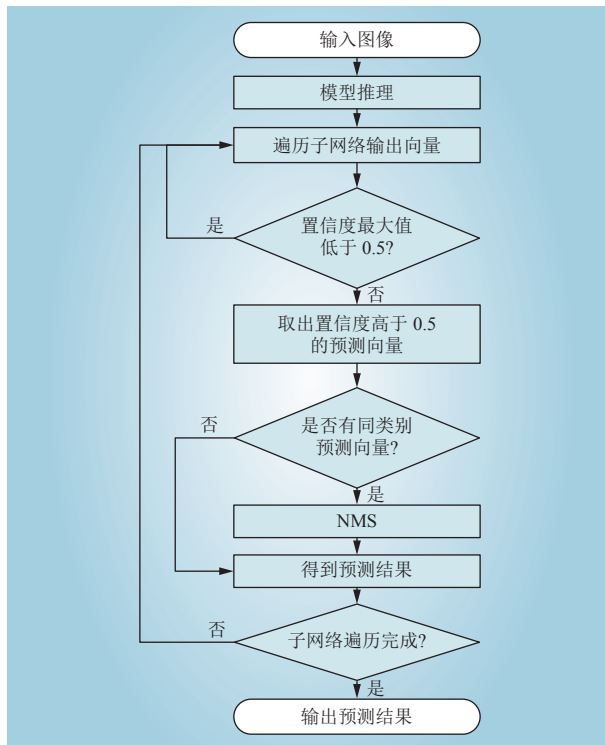


图 7 D-NMS 算法流程
Fig. 7 Process of D-NMS

情况。故对每个子网络的预测结果进行 NMS 后，可直接输出预测结果，无须进行其他操作。

3 实验结果与分析

3.1 基于语义信息距离的缺陷类别聚簇

采用南瑞集团公司收集标注的变电运维场景下缺陷图像数据集，包含 17 类缺陷，共计约 25 000 张图片，其中标签名称和含义如表 2 所

表 2 数据集缺陷类别
Table 2 Defect classes of dataset

类别序号	类别含义	类别序号	类别含义
1	表计：表盘模糊	10	开关柜：压板合
2	盖板破损	11	呼吸器：硅胶变色
3	油温状态：油封异常	12	异物：鸟巢
4	未穿安全帽	13	表计读数异常
5	呼吸器：硅胶桶破损	14	吸烟
6	渗漏油：地面油污	15	未穿工装
7	绝缘子破裂	16	表计：表盘破损
8	异物：挂空悬浮物	17	箱门闭合异常
9	表计：外壳破损		



示。可以看出，该数据集中的 17 类缺陷发生场景跨度很大，关联设备不尽相同，但也存在数个缺陷来源于同一类设备的情况。本数据集缺陷类别间的语义信息距离有较大差异，忽略这种差异而直接对缺陷采用独热编码是不合适的。因此，需考虑类别间语义信息距离带来的影响，搭建更加适配于变电运维场景的深度学习模型。

3.2 聚类解耦策略应用及效果分析

选取 3 个位置的特征图，计算 2.1 节中提到的空间金字塔池化向量以表征各个类别的语义信息，而后根据式 (1) 对由相同位置特征图生成的 SPP 向量计算 f_{eval} ，以量化特征图中各个缺陷间的语义信息差异，在此基础上评估生成特征图的子网络对于不同种类缺陷的语义区分能力，结果如表 3 所示。 f_{eval} 越小，表明网络对于多类别缺陷的语义区分能力越强。对比表 3 中的计算结果可知，CSP3 输出特征图对应的评估结果 f_{eval} 最小，故选取 CSP3 的输出作为解耦的起始位置。

表 3 特征图评估结果

Table 3 Results of feature map evaluation

层	特征图像素尺寸	评估结果
CSP1	80×80×128	0.003 201 18
CSP2	40×40×256	0.001 697 94
CSP3	20×20×512	0.000 936 42

根据 2.1 节聚类策略，对变电运维缺陷的聚类结果如表 4 所示。选取各类缺陷典型图像按照聚类结果分组，如图 8 所示。

表 4 类别聚类结果

Table 4 Results of classes clustering

聚类序号	类别含义
1	表计：表盘模糊、表计：表盘破损、表计：外壳破损、表计读数异常
2	盖板破损、渗漏油；地面油污、绝缘子破裂、箱门闭合异常
3	呼吸器：硅胶变色、呼吸器：硅胶桶破损、开关柜：压板合、异物；挂空悬浮物、异物；鸟巢、油温状态；油封异常
4	未穿安全帽、未穿工装、吸烟

根据表 4 的聚类结果和图 8 的呈现效果，不难看出该聚类策略能够较好地反应缺陷类别之间的语义信息差距。例如，第 1 簇中的类别全都与表计缺陷相关；第 2 簇主要为设备的破损缺陷；第 3 簇主要为设备工作状态的异常缺陷；第 4 簇

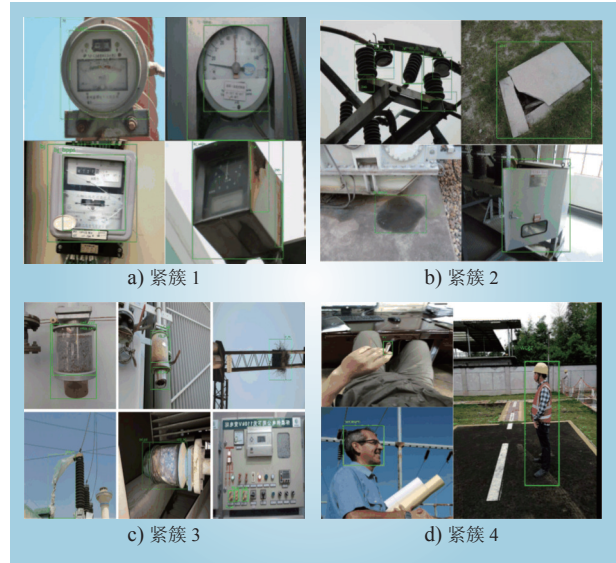


图 8 聚类效果展示

Fig. 8 Exhibition of cluster results

中的缺陷均与工作人员违规有关。聚类结果也进一步佐证了虽然变电运维场景中缺陷类别种类繁多，但是类别间的语义信息距离存在很大差异，忽略这些差距直接对缺陷进行独热编码是不合理的。根据聚类结果搭建 SDB-DDM，在通过前端网络提取公共特征后，将后端的特征融合网络解耦为若干个子网络，以适应各个簇内不同缺陷的检测需求。

3.3 模型检测性能分析

根据 3.2 节聚类方案，搭建检测模型并对其进行消融实验，以验证所提改进思路的可行性，消融实验结果如表 5 所示。

表 5 消融实验结果

Table 5 Ablation experiment results

模型	模型描述	参数量/ M	mAP/ %	推理速度/ fps
SDB-DDM	基准模型	27.7	55.60	12.0
SDB-DDM+CSP	模型结构优化	19	57.10	16.1
SDB-DDM+CSP+WAF	改进训练策略1	19	64.16	16.1
SDB-DDM+CSP+LPL	改进训练策略2	19	65.29	16.2
SDB-DDM+CSP+WAF+LPL	改进训练策略3	19	69.68	16.3
SDB-DDM+CSP+WAF+LPL+D-NMS	改进推理策略	19	69.64	20.2

通过对实验结果进行分析可知，在根据聚类解耦策略搭建解耦式模型并进行训练时，初始模

型的表现并不好,推测是因为直接对各个子网络进行训练时,分配给各个子网络的目标过少,导致子网络的正负样本失衡引起过拟合。引入 CSP 后,模型的精度提升了 1.5 个百分点,参数量减少了 8.7 MB,推理速度也随之提升。实验结果与 CSP 的设计初衷相符,表明 CSP 结构更加适配算力有限的计算平台。

为解决子网络的正负样本失衡问题,提出闭合式训练策略,并进一步提出加权锚框融合策略 WAF 对各个子网络输出结果加权以平衡子网络的输出贡献,在不增加网络参数和推理时间的前提下,将网络的平均精度均值 mAP 提升了 7.06%。在采用闭合式训练后,为提升子网络的缺陷检测能力,提出局部预测损失 LPL,通过对子网络的置信度预测结果构建损失函数,以保证子网络预测的可靠性。对解耦式网络模型加入 LPL 后,模型在保证原有检测速度的同时,mAP 提升了 8.19 个百分点。而在同时加入 WAF 和 LPL 时,由于 WAF 和 LPL 没有给模型推理带来额外的计算成本,模型的检测速度依然没有受到影响,但是模型的 mAP 相较于原始模型提升了 12.58 个百分点。上述实验结果一方面说明 WAF 与 LPL 的有效性,另一方面也从侧面反映了聚簇结果的合理性。

加入 D-NMS 后,模型在维持原有检测精度的同时,推理速度提升了约 24%,推测是由于单张图像中的目标有限,在进行推理时可以根据置信度直接忽略模型中部分子网络的检测结果,从而加快了推理速度。

将 SDB-DDM 与目前 2 种主流的目标检测算法(YOLO-v4^[20]、CenterNet^[25])进行性能对比,如表 6 所示。相对于上述 2 种目标检测算法,SDB-DDM 模型在保证较高的检测精度的同时,模型的参数量降低了 90%,推理速度提升了三四倍。

将 SDB-DDM 模型与目前最新的实时目标检

测模型 YOLOX^[18]进行性能对照,选取 YOLOX 中与 SDB-DDM 参数相仿的 YOLOX-tiny 进行性能对比,参见表 6。在同平台下模型参数量和检测精度均略优于 YOLOX-tiny,其中精度提升了 1.36 个百分点,参数量下降了 5%,但是推理速度提升了 34%,其解耦式的网络结构也可以更好地应对变电站中缺陷类型繁杂、缺陷类别间语义信息跨度较大的场景特征。

选取部分模型检测效果如图 9 所示。




图 9 缺陷图像检测结果展示

Fig. 9 Exhibition of detecting defect images

4 结论

针对变电运维场景缺陷种类繁多且不同缺陷类别间语义信息当前变电设备缺陷检测模型存储和计算成本高的问题,提出一种基于语义信息解耦的轻量化缺陷检测模型 SDB-DDM。首先,通过分析变电巡检缺陷检测场景特征,提出一种基于类别 SPP 向量的变电设备缺陷类别分组策略;然后,根据分组结果搭建分散式检测模型,并进一步提出 WAF 与 LPL 改进策略以提升模型的检测精度与泛化能力;最后,在模型推理阶段,考虑到变电缺陷检测场景特征,提出一种 D-NMS 加快边框抑制过程,降低模型运算和存储需求量。

实验结果表明,WAF 与 LPL 策略分别能在不增加模型推理时间的前提下使得模型的检测精度提升了 7.06 个百分点和 8.19 个百分点,二者的综合使用将模型精度提升了 12.58 个百分点。由此获得了具备较高检测精度的轻量化检测模型,从而对变电巡检缺陷类别间语义信息跨度较大的场景特征具备更好的应对能力。

表 6 模型性能对比

Table 6 Models performance comparison

模型描述	模型名称	参数量/M	mAP/ %	推理速度/fps
对照模型	YOLO-v4		77.50	5.38
	CenterNet	191	71.40	7.30
	YOLOX-tiny	20	68.28	15.10
本文模型	SDB-DDM + CSP + WAF + LPL + D-NMS	19	69.64	20.20



参考文献：

- [1] 罗琨, 时永肖, 李正新, 等. 智能变电站继电保护装置寿命模型及其辨识方法 [J]. *智慧电力*, 2021, 49(1): 96–101.
LUO Kun, SHI Yongxiao, LI Zhengxin, *et al.* Life model and identification method of relay protection device in smart substation[J]. *Smart Power*, 2021, 49(1): 96–101.
- [2] 李肖博, 于杨, 姚浩, 等. 新一代智能变电站采控装置 [J]. *中国电力*, 2022, 55(4): 85–92.
LI Xiaobo, YU Yang, YAO Hao, *et al.* Sample-control-device of smart substation[J]. *Electric Power*, 2022, 55(4): 85–92.
- [3] 李泽文, 王志刚, 穆利智, 等. 变电站智能安监可穿戴设备设计 [J]. *电力科学与技术学报*, 2022, 37(4): 217–226.
LI Zewen, WANG Zhigang, MU Lizhi, *et al.* Design of wearable equipment for substation intelligent safety supervision[J]. *Journal of Electric Power Science and Technology*, 2022, 37(4): 217–226.
- [4] 李自若, 沈曦, 张亦兵, 等. 基于深度强化学习的智慧变电站网络异常检测方法 [J]. *南方电网技术*, 2021, 15(6): 98–105.
LI Ziruo, SHEN Xi, ZHANG Yibing, *et al.* Network anomaly detection method for smart substation based on deep reinforcement learning[J]. *Southern Power System Technology*, 2021, 15(6): 98–105.
- [5] 高熠, 田联房, 杜启亮. 基于 Mask R-CNN 的复合绝缘子过热缺陷检测 [J]. *中国电力*, 2021, 54(1): 135–141.
GAO Yi, TIAN Lianfang, DU Qiliang. Overheating defect detection of composite insulator based on mask R-CNN[J]. *Electric Power*, 2021, 54(1): 135–141.
- [6] 王帅, 姜敏, 李江林, 等. 全维度智能变电站设备状态监测关键技术研究 [J]. *电测与仪表*, 2020, 57(7): 82–86.
WANG Shuai, JIANG Min, LI Jianglin, *et al.* Research on key technologies of condition monitoring of full-dimensional intelligent substation equipment[J]. *Electrical Measurement & Instrumentation*, 2020, 57(7): 82–86.
- [7] 刘颖, 胡楠, 杨壮观, 等. 基于深度学习的电网监控视频中工作人员检测与识别 [J]. *沈阳工业大学学报*, 2019, 41(5): 544–548.
LIU Ying, HU Nan, YANG Zhuanguan, *et al.* Detection and identification of staff in power grid monitoring video based on deep learning[J]. *Journal of Shenyang University of Technology*, 2019, 41(5): 544–548.
- [8] 王旭红, 李浩, 樊绍胜, 等. 基于改进 SSD 的电力设备红外图像异常自动检测方法 [J]. *电工技术学报*, 2020, 35(增刊1): 302–310.
WANG Xuhong, LI Hao, FAN Shaosheng, *et al.* Infrared image anomaly automatic detection method for power equipment based on improved single shot multi box detection[J]. *Transactions of China Electrotechnical Society*, 2020, 35(S1): 302–310.
- [9] 王凯, 王健, 刘刚, 等. 基于 RetinaNet 和类别平衡采样方法的销钉缺陷检测 [J]. *电力工程技术*, 2019, 38(4): 80–85.
WANG Kai, WANG Jian, LIU Gang, *et al.* Defect detection of pins based on RetinaNet and class balanced sampling methods[J]. *Electric Power Engineering Technology*, 2019, 38(4): 80–85.
- [10] 黄锐勇, 戴美胜, 郑跃斌, 等. 电力设备红外图像缺陷检测 [J]. *中国电力*, 2021, 54(2): 147–155.
HUANG Ruiyong, DAI Meisheng, ZHENG Yuebin, *et al.* Defect detection of power equipment by infrared image[J]. *Electric Power*, 2021, 54(2): 147–155.
- [11] 位一鸣, 童力, 罗麟, 等. 基于卷积神经网络的主变压器外观缺陷检测方法 [J]. *浙江电力*, 2019, 38(4): 61–68.
WEI Yiming, TONG Li, LUO Lin, *et al.* An exterior defects detecting method of main transformer based on convolutional neural networks[J]. *Zhejiang Electric Power*, 2019, 38(4): 61–68.
- [12] 张晶焯, 余楚云, 伍国兴, 等. 基于增强特征金字塔和可变形卷积的绝缘子缺陷检测 [J]. *电力工程技术*, 2021, 40(4): 155–160.
ZHANG Jingzhuo, SHE Chuyun, WU Guoxing, *et al.* Insulator defect detection based on enhanced feature pyramid and deformable convolution[J]. *Electric Power Engineering Technology*, 2021, 40(4): 155–160.
- [13] 罗鹏, 王波, 马恒瑞, 等. 基于组合式目标检测框架的低漏报率缺陷识别方法 [J]. *高电压技术*, 2021, 47(2): 454–464.
LUO Peng, WANG Bo, MA Hengrui, *et al.* Defect recognition method with low false negative rate based on combined target detection framework[J]. *High Voltage Engineering*, 2021, 47(2): 454–464.
- [14] 顾晓东, 唐丹宏, 黄晓华. 基于深度学习的电网巡检图像缺陷检测与识别 [J]. *电力系统保护与控制*, 2021, 49(5): 91–97.
GU Xiaodong, TANG Danhong, HUANG Xiaohua. Deep learning-based defect detection and recognition of a power grid inspection image[J]. *Power System Protection and Control*, 2021, 49(5): 91–97.
- [15] 应樱. 基于改进 Faster R-CNN 的变电站设备缺陷检测算法研究 [D]. 杭州: 浙江大学, 2021.
YING Ying. Research on defect detection algorithm of substation equipment based on improved Faster R-CNN[D]. Hangzhou: Zhejiang University, 2021.
- [16] 尹思宇. 深度学习在变电站电力设备缺陷检测中的应用研究 [D].

- 成都: 电子科技大学, 2020.
- YIN Siyu. Research on application of deep learning in defect detection of substation power equipment[D]. Chengdu: University of Electronic Science and Technology of China, 2020.
- [17] 徐海洋. 变电站设备表面缺陷图像识别关键技术研究 [D]. 南宁: 广西大学, 2021.
- XU Haiyang. Research on key technologies of image recognition for surface defects of substation equipment[D]. Nanning: Guangxi University, 2021.
- [18] GE Z, LIU S, WANG F, *et al.* YOLOX: exceeding YOLO series in 2021[EB/OL]. 2021: arXiv: 2107.08430.<https://arxiv.org/abs/2107.08430>.
- [19] WANG C Y, LIAO H Y M, WU Y H, *et al.* CSPNet: a new backbone that can enhance learning capability of CNN[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Seattle, WA, USA. IEEE, 2020: 1571–1580.
- [20] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: optimal speed and accuracy of object detection[EB/OL]. 2020: arXiv: 2004.10934.<https://arxiv.org/abs/2004.10934>.
- [21] REDMON J, FARHADI A. YOLOv3: an incremental improvement[EB/OL]. 2018: arXiv: 1804.02767.<https://arxiv.org/abs/1804.02767>.
- [22] SALEH S, PAUL M, GREG F. “How many images do I need?” Understanding how sample size per class affects deep learning model performance metrics for balanced designs in autonomous wildlife monitoring[J]. *Ecological Informatics*, 2020, 57: 101085.
- [23] HE K M, ZHANG X Y, REN S Q, *et al.* Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 37(9): 1904–1916.
- [24] BODLA N, SINGH B, CHELLAPPA R, *et al.* Soft-NMS —improving object detection with one line of code[C]//2017 IEEE International Conference on Computer Vision (ICCV). Venice, Italy. IEEE, 2017: 5562–5570.
- [25] DUAN K W, BAI S, XIE L X, *et al.* CenterNet: keypoint triplets for object detection[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, Korea (South). IEEE, 2020: 6568–6577.

作者简介:

张鑫 (1987—), 男, 硕士, 高级工程师, 从事电力系统通信、电力智能运维技术及应用研究, E-mail: zhangxin4@sgepri.sgcc.com.cn;

仲林林 (1990—), 男, 通信作者, 博士, 副研究员, 从事高电压技术、放电等离子体技术、人工智能技术研究, E-mail: linlin@seu.edu.cn.

(责任编辑 于静茹)

Decoupled Sematic Distance Based Multi-class Defect Scene Detecting for Substations

ZHANG Xin^{1,2}, YE Junjie³, CUI Yao^{1,2}, HUANG Xin^{1,2}, ZHONG Linlin³

(1. NARI Group Corporation (State Grid Electric Power Research Institute), Nanjing 211106, China; 2. State Key Laboratory of Smart Grid Protection and Control, Nanjing 211106, China; 3. School of Electrical Engineering, Southeast University, Nanjing 210096, China)

Abstract: Due to the complexity and differences of defect types in substations, traditional deep learning models for defects detection lack comprehensive response ability. It proposes a sematic distance based decoupling detection model. Firstly, the decoupled model structure is determined by clustering defect classes according to the semantic information distance between each other. Then, the weighted anchor fusion and local prediction loss techniques are used to improve the model performance. Meanwhile, the decoupled non-maximum suppression strategy is proposed to accelerate the model inference process. The experiment results show that the mean average precision of the model reaches 69.68%. Compared with YOLOX, which has been recognized as the best real-time object detection model, the accuracy of proposed model is improved by 1.36 percentage points, the parameter quantity is reduced by 5%, and the inference speed is improved by 34%.

This work is supported by Science and Technology Project of State Grid Electric Power Research Institute (No.524606210002).

Keywords: substation maintain and operation scene; defect detection; deep learning; semantic information distance; decoupled model