

DOI: 10.19650/j.cnki.cjsi.2412999

# 基于元学习的变电设备小样本缺陷图像检测\*

仲林林<sup>1</sup>, 吴奇<sup>1</sup>, 叶俊杰<sup>1,2</sup>, 高丙团<sup>1</sup>

(1. 东南大学电气工程学院 南京 210096; 2. 国网上海市电力公司市区供电公司 上海 200080)

**摘要:** 缺陷图像检测是变电设备运维的重要技术手段。然而由于缺陷样本的稀缺,传统的基于海量数据训练的深度学习模型在实际应用中面临小样本缺陷检测的挑战。为此,本文引入元学习思想,提出一种面向变电设备小样本缺陷图像检测的深度学习模型。该模型的核心是前端网络权重的优化和面向小样本测试任务的模型微调。前者通过基于语义信息的任务生成策略,使模型能够快速适应新任务;后者则通过基于元学习的网络优化方法对模型进行微调,使模型能够在新任务上获得优异性能。实验结果表明,本文提出的改进方法可以使模型的综合检测精度提升7.33%,新增类别的检测精度提升11.48%,显著改善了模型对小样本缺陷和新增类别缺陷的检测性能。

**关键词:** 变电设备; 缺陷检测; 图像检测; 元学习; 小样本

**中图分类号:** TP391.4 TH701 **文献标识码:** A **国家标准学科分类代码:** 470.4051

## Meta-learning-based few-shot image detection of defects in substation equipment

Zhong Linlin<sup>1</sup>, Wu Qi<sup>1</sup>, Ye Junjie<sup>1,2</sup>, Gao Bingtuan<sup>1</sup>

(1. School of Electrical Engineering, Southeast University, Nanjing 210096, China; 2. State Grid Shanghai Electric Power Company Urban Power Supply Company, Shanghai 200080, China)

**Abstract:** Defect image detection is an important technical tool for substation equipment operation and maintenance. However, due to the scarcity of defect samples, the traditional deep learning model based on massive data training faces the challenge of few-shot defect detection in practical applications. Therefore, this article introduces the idea of meta-learning and proposes a deep learning model for few-shot defect image detection of substation equipment. The core of the model is the optimization of front-end network weights and model fine-tuning for few-shot testing tasks. The former enables the model to quickly adapt to new tasks through a task generation strategy based on semantic information, while the latter fine-tune the model through a network optimization method based on meta-learning. Therefore, the model can obtain excellent performance on new tasks. The experimental results show that the improved method can enhance the model's overall detection accuracy by 7.33% and the detection accuracy of the new categories by 11.48%, which significantly improves the detection performance on few-shot defects and defects of new categories.

**Keywords:** substation equipment; defect detection; image detection; meta learning; few-shot

## 0 引言

目前,大多变电站已安装图像和视频监控设备用以采集站内各类运维图像信息,并结合智能处理算法分析图像数据,以期逐步实现智能化变电运维<sup>[1-3]</sup>。

然而,目前变电运维图像智能处理主要依赖数据驱

动的深度学习算法<sup>[4-7]</sup>,需要大量样本数据,且模型性能受图像数量影响<sup>[8]</sup>,缺乏对新增类别缺陷和稀有缺陷的检测能力<sup>[9-11]</sup>。一方面,变电站中部分缺陷类别对应的样本数据采集难度较大,不易收集到足够多的样本以构建优质的训练数据集;另一方面,变电运维场景的潜在缺陷类别可能会随着应用场景的改变而不断更新,导致新增缺陷类别对应的样本更为稀少<sup>[12]</sup>。

收稿日期:2024-06-27 Received Date: 2024-06-27

\* 基金项目:江苏省自然科学基金(BK20231427)、国家自然科学基金(92066106)、东南大学“至善青年学者”支持计划(中央高校基本科研业务费)(2242022R40022)项目资助

近年来,如何提升深度学习模型对于小样本缺陷的检测效果是计算机视觉领域的重要研究方向<sup>[13]</sup>。目前的小样本学习方法主要分为基于度量学习、基于模型初始化以及基于权重微调的检测方法。基于度量学习的小样本检测方法,其基本思想是:同类别样本在深度学习网络中的向量距离小于异类样本对应的距离,因此在面对小样本类别检测任务时,可以通过计算新类别与已知类别特征向量的相似度,实现对新类别样本的检测。Koch 等<sup>[14]</sup>提出用孪生网络来解决小样本分类问题,搭建了一对参数相同的孪生网络(siamese neural networks)并训练其对于不同类别的分类能力,通过计算两个网络输出特征向量的  $L^1$  距离判断两张小样本图像是否属于一类。Vinyals 等<sup>[15]</sup>在孪生网络的基础上进一步提出匹配网络(matching networks),首先在已知类别的数据集上训练模型使其具备特征提取与编码能力,然后根据小样本数据微调编码权重,从而实现对小样本数据的快速分类。Snell 等<sup>[16]</sup>提出原型网络(prototypical networks),认为所有类别数据在高维空间中存在一个对应的典型向量,通过计算小样本类别生成的特征向量与各类典型特征向量的距离可以实现样本分类。基于模型初始化的小样本检测方法将模型投入多个预设任务中进行训练,基于模型在各个任务上少量训练后的综合性能优化模型的初始权重,从而使得模型在面对新任务时只需少量训练即可收敛。Finn 等<sup>[17]</sup>提出了一种理论上可以对任何结构的深度学习模型进行权重优化的双循环训练架构模型无关元学习(model-agnostic meta learning, MAML),在内循环过程中将模型投入各个训练任务中执行少量迭代训练,内循环结束后在外循环阶段计算模型在各个任务上的综合损失以更新模型的初始权重。这一方法跳出了传统深度学习模型的数据驱动机制,以模型在各个任务上的综合表现作为训练目标,提升了模型在面对小样本学习任务时的泛化能力。在此基础上,Li 等<sup>[18]</sup>对 MAML 的实施细节进行了进一步优化,提高了 MAML 的稳定性和泛化能力。Jamal 等<sup>[19]</sup>则基于 MAML 提出任务无偏元学习方法(task-agnostic meta learning, TAML),通过调整外循环的损失计算方式以及引入偏置修正任务权重的方式,避免 MAML 模型在训练过程中偏向某些训练任务,从而提升模型的任务泛化能力。Jiang 等<sup>[20]</sup>在 TAML 的基础上,通过在外循环过程中引入注意力机制提升模型对于训练任务的偏差修正能力,使得模型可以在无偏任务中训练,进一步提升模型的泛化性。

基于权重微调的小样本检测方法首先在样本丰富类别构成的数据集上训练模型至收敛,在处理样本较少的新类别时,基于新的样本对部分参数进行微调即可。Wang 等<sup>[21]</sup>提出了一种两阶段微调方法(two-stage fine-tuning approach, TFA),首先将两阶段模型在基类中完成

的深度学习模型的训练,在将其迁移到新的检测类别时,只对最后一层神经元的权重进行微调训练,并通过实验验证了此方法的可行性。Sun 等<sup>[22]</sup>则在 TFA 的基础上引入对比建议编码损失(contrastive proposals encoding loss, CPE Loss)并在微调过程中改良损失函数,使得模型在小样本数据集微调过程中更加平稳,最终的精度也显著提升。

由此可见基于度量的小样本检测方法<sup>[23]</sup>可以用于评估变电设备缺陷的类别相似度差异,基于初始化的小样本检测方法可以优化网络参数,提升模型对于新增类别与小样本类别的应对能力,基于权重微调的小样本检测方法可以在面对新增类别检测任务时提升快速模型的检测性能。因此,将元学习思想引入到面向变电设备缺陷图像检测的深度学习模型中,用以解决传统基于大量数据训练的图像检测模型在变电设备缺陷样本稀缺情况下训练失败的问题。本文提出的改进模型主要包括:1)前端网络权重的优化,通过提出了一种基于语义信息的任务生成策略,使得缺陷图像检测模型能够快速适应新任务。2)面向小样本测试任务的模型微调,通过提出一种基于元学习的公共特征提取网络的优化训练方法,对训练好的模型进行微调,使得缺陷图像检测模型能够在新任务上获得优异性能。最后本文通过实验结果证明了提出的模型在新的样本缺陷检测任务中展现出较高的平均精度,且能够显著改善模型对新增缺陷类别的检测性能。

## 1 变电设备缺陷图像检测场景中的小样本问题

在构建变电设备缺陷图像数据集时,可能出现部分缺陷对应样本过少的问题(即小样本问题),原因如下。

1) 由于部分缺陷类型样本收集难度大,数据集中此类缺陷的样本数量本身就比较少。表 1 列举了本文所使用的变电设备缺陷图像数据集中各类缺陷样本的数量及占比,可以看出在该数据集中,缺陷类别 5 对应的样本占比极低,其他如类别 3、类别 9 等对应的样本占比也显著低于平均值。在此情况下,直接根据该数据集训练的深度学习模型可能难以检测到类别 5 缺陷的有效特征,对于类别 3 和 9 的缺陷检测效果也会受到影响。

2) 变电设备的潜在缺陷类型复杂多样,训练一个可以涵盖所有缺陷类型的深度学习模型难度较大。因此在实际应用中,一般会根据场景特征及变电运维需求从潜在缺陷类型集合中选取若干关键缺陷类别构建深度学习模型。例如,随着变电运维内部场景及运维需求的改变,缺陷检测任务会逐步更新,任务中包含的缺陷类别也随之改变,进而引入不在原有数据集中的新增类别。对于

表 1 变电设备缺陷图像数据集类别分布  
Table 1 Category distribution of defect image dataset  
for substation equipment

| 类别序号 | 类别含义      | 样本占比/% |
|------|-----------|--------|
| 1    | 表计:表盘模糊   | 16.43  |
| 2    | 盖板破损      | 4.14   |
| 3    | 油位状态:油封异常 | 1.52   |
| 4    | 未穿安全帽     | 3.16   |
| 5    | 呼吸器:硅胶桶破损 | 0.09   |
| 6    | 渗漏油:地面油污  | 5.37   |
| 7    | 绝缘子破裂     | 5.36   |
| 8    | 异物:挂空悬浮物  | 12.85  |
| 9    | 表计:外壳破损   | 2.03   |
| 10   | 开关柜:压板分断  | 8.09   |
| 11   | 呼吸器:硅胶变色  | 10.87  |
| 12   | 异物:鸟巢     | 8.32   |
| 13   | 表计读数异常    | 6.74   |
| 14   | 吸烟        | 2.28   |
| 15   | 未穿工装      | 3.41   |
| 16   | 表计:表盘破损   | 3.77   |
| 17   | 箱门闭合异常    | 5.55   |

这些新增缺陷类别,往往难以在短时间内收集到足够的样本数据,因而带来了包含新类别数据的小样本问题。小样本问题是实现变电设备智能运维需要解决的关键问题之一。一方面,小样本问题带来的样本分布不均会影响模型的训练效果;另一方面,传统的深度学习模型难以有效应对新增类别缺陷。如图 1 所示,当检测任务内包含的缺陷类别发生改变时,传统方法是通过收集足量样本构成新的拓展数据集,再将模型投入拓展数据集中重新开始训练得到新的深度学习模型。这种学习模式不仅造成了计算和存储资源的浪费,也没有利用之前训练完成的模型信息,而且模型的训练效果也会受到新增类别样本数量不足的影响。




图 1 变电设备缺陷图像检测模型的拓展学习过程  
Fig. 1 The extended learning process of defect image  
detection model of substation equipment

2 元学习模型简介

为了解决上述变电设备缺陷图像检测中存在的小样本问题,本文引入元学习思想对变电设备缺陷图像检测模型进行改进,以提升模型对小样本缺陷的检测能力。

元学习(meta learning)理论的提出最早可以追溯到1987年<sup>[24-25]</sup>,其学习样本并非传统机器学习方法使用的样本数据,而是若干个预设的训练任务。元学习在训练过程中根据模型在各个训练任务上的综合表现来执行梯度反馈,使得训练成型的模型能够快速适应新的学习任务。

近年来,随着深度学习模型涵盖的任务类型越来越多,引入元学习思想对模型进行改良以提升其对多个学习任务的综合应对能力,已逐渐成为一个重要的研究方向。本文引入模型无关元学习方法 MAML 来改良变电设备缺陷图像检测模型的架构与训练策略<sup>[26-27]</sup>。MAML 的本质是一种可以适配于任意深度学习模型的算法框架<sup>[17]</sup>,通过其内外双循环结构优化模型权重,使得模型在面对新的学习任务时可以快速迭代收敛。MAML 的基本执行过程如图 2 所示。




图 2 基于 MAML 的元学习过程  
Fig. 2 MAML-based meta-learning process

主要包括如下步骤:

- 1) 选定模型结构,确定模型中需要进行元学习的所有变量记为  $\theta$ ,初始化  $\theta$  后得到初始模型,记为  $\theta_0$ 。
- 2) 根据应用场景构建训练任务集合  $\{T_1, T_2, T_3, \dots\}$ ,每个任务内均包含若干用于训练与测试的样本数据,分别称为支持集与查询集。
- 3) 将初始模型投入到训练任务中执行适当轮次的迭代训练后,计算该模型查询集中的测试损失  $L_{\text{train}}^i$ 。
- 4) 切换训练任务,重复 3) 至模型在所有训练任务中均完成训练,计算模型的综合训练损失  $L_{\text{train}} = \sum L_{\text{train}}^i$ ,并据此计算模型的综合梯度反馈  $\theta' = \nabla L_{\text{train}}$ 。
- 5) 更新输出模型参数  $\theta_1 = \theta_0 - \eta \times \theta'$ ( $\eta$  为学习率)。
- 6) 重复 3) ~ 5) 至元学习模型收敛,得到成型模型  $\theta^*$ 。



7) 在面对新的学习任务  $T'_{\text{new}}$  时,将成型模型  $\theta^*$  投入到  $T'_{\text{new}}$ , 微调训练得到新类别检测任务的最优模型  $\theta^*_{\text{test}}$ 。

可见, MAML 模型在训练过程中立足于模型在任务层面的表现, 其学习目标在于改良模型使其在各个训练任务中的综合表现达到最优。由于训练过程中任务与任务间相互独立, 且初始模型的训练损失来自于模型在各个任务查询集中的测试损失, MAML 模型具有较强的泛化能力, 且可以更快适应新的学习任务。

### 3 基于元学习的变电设备缺陷图像检测模型

将 MAML 元学习思想应用到变电设备缺陷图像检测中, 提出一种基于元学习的小样本缺陷图像检测模型。整体架构如图 3 所示, 包括元学习任务生成、公共特征提取网络的优化、面向测试任务的模型微调 3 个主要步骤。通过预设小样本训练任务以及搭建双循环训练网络优化模型权重的方式来提升模型对于小样本缺陷的检测能力。




图 3 基于元学习的变电设备小样本缺陷图像检测模型整体架构

Fig. 3 The overall architecture of few-shot defect image detection model of substation equipment based on meta-learning

#### 3.1 基于语义信息的元学习任务生成策略

为了提升模型对包含新类别的小样本缺陷检测任务的处理能力, 首先结合变电运维场景特征, 提出了一种基于语义信息的元学习训练任务生成策略 (semantic information-based meta learning task generation, SI-MLTG), 将缺陷类别间的语义信息相似度作为训练任务生成的重要参考指标, 使得生成的训练任务具有更高的实践可行性和场景合理性。该生成策略主要过程如下。

##### 1) 训练-测试类别划分

如图 4 所示, 按照各个类别的样本数量划分出训练任务与测试任务样本集。假设现有数据集中各类别按照样本的多寡可以分为样本充裕类别 (共计  $a$  类) 和样本

稀少类别 (共计  $r$  类)。本文从样本充裕类别数据集选取样本数据构建训练任务, 对于单个训练任务, 按照其包含的缺陷类别各提取  $s$  张样本图像作为该训练任务的支持集, 另提取  $q$  张样本图像作为该训练任务的查询集。而在构建测试任务时, 样本稀疏类别也被纳入学习范围, 模型将从所有类别 (共计  $a+r$  类) 中各选取  $n_s$  张图像作为支持集,  $n_q$  张图像作为查询集。




图 4 元学习模型的数据集分割

Fig. 4 Dataset segmentation of the meta-learning model

##### 2) 学习任务各类样本数据量约束

为了提升模型面对小样本学习任务时的应对能力, 本文在构建支持集与查询集时对各类缺陷选取出的样本数量加以限制。在实际应用场景中, 对于收集难度较大的缺陷类别以及随着场景变化而产生的新增类别, 收集数十张有效样本已存在较大难度, 认为图 4 中测试任务内各类缺陷的样本数量 ( $n_s$  与  $n_q$ ) 不宜超过 10 张。在此基础上, 还需要对训练任务的样本数量 ( $s$  与  $q$ ) 加以限制, 避免训练任务的样本数量远超测试任务, 否则模型难以在训练过程中提升其对小样本缺陷的检测能力。在测试任务中各类缺陷的样本数量不超过 10 张的前提下, 训练任务的各类样本数量不宜超过 50 张, 以避免训练任务与测试任务的差异性过大, 进而影响模型的学习效果。

##### 3) 基于语义信息的训练任务生成

在完成训练-测试任务的类别划分和样本数量约束后, 接下来需要生成训练任务。现有方法在设计训练任务时, 一般会依照相同的生成策略随机生成若干训练任务, 以保证训练任务之间的差异尽量均匀。以本文所研究的变电设备缺陷检测问题为例, 训练任务中共有  $a$  类缺陷, 现有方法一般是从此  $a$  类缺陷中随机挑选  $b$  类 ( $b < a$ ) 作为一个训练任务, 重复  $t$  次后得到  $t$  个包含  $b$  类缺陷的训练任务。然而这一任务生成方式并不适合变电设备缺陷检测场景, 原因如下。

(1) 变电设备缺陷与设备类型有很强的关联性, 变电运维场景变化带来的缺陷类别的改变并非随机增减, 这就导致随机抽取产生的 2 个任务之间的类别改变在现实场景中并不合理。以本文所采用的数据集为例, 假设通过随机抽取产生了任务 A, 其中包含“表计: 表盘模糊”与“表计: 外壳破损”这 2 种一定发生在表计设备上缺陷

类型,且只包含这2种表计相关缺陷;而后,再次随机抽取产生任务B,其中只包含“表计:表盘模糊”这1种表计相关缺陷。但是在实际场景中,如果变电运维场景发生变动,任务A中的2种表计相关缺陷应该会被同时移除或保留,不可能出现任务B中的类别情况。

(2) 由于不同缺陷类型的关联设备不尽相同,致使缺陷与缺陷间的关联性差异很大,例如“表计:表盘模糊”与“表计:外壳破损”的关联性一定远高于其与“异物:鸟巢”的关联性,这就导致使用随机抽样选取样本的方式很难保证各个训练任务间的差异均匀度。

为此,本文提出基于语义信息的训练任务生成策略,在进行元学习训练任务设计时,充分考虑类别间的语义信息差距,以每个语义信息相对接近的分组作为基准任务,在基准任务的基础上进行适当增减后生成等量拓展任务,从而构成元学习的训练任务集合。其具体步骤如下。

步骤1:将归属于同一分组的各类缺陷划为1组,生成一个基准任务;

步骤2:计算同一分组中各缺陷类别到该分组中心的距离,剔除距离分组中心最远的类别,以分组内剩余的缺陷类别生成一个拓展任务;

步骤3:计算所有不在该分组中的缺陷类别到该分组中心的距离,选择距离该分组中心最近的非该分组缺陷类别,将此缺陷类别与该分组中其他类别合并生成一个拓展类别。

图5展示了基于语义信息的元学习训练任务生成过程。




图5 基于语义信息的元学习训练任务生成

Fig. 5 Schematic diagram of Meta-learning training task generation based on semantic information

图中每个几何符号代表一个缺陷类别,几何符号之间的远近代表了类别间的语义信息距离差异,按照图中几何符号的分布情况,可以将缺陷分为3个分组。其中 $c_1 \sim c_4$ 被划归为1个分组,故基准任务中包含的类别 $Task1 = \{c_1, c_2, c_3, c_4\}$ 。而后,以该分组中心为圆心作

同心圆可知, $c_4$ 是该分组所有类别中距离分组中心最远的类别, $d_1$ 是非该分组类别中距离分组中心最近的类别。因此对基准任务中包含的类别剔除得到拓展任务类别 $Task2 = \{c_1, c_2, c_3\}$ ,在基准类别中添加 $d_1$ 得到拓展任务类别 $Task3 = \{c_1, c_2, c_3, c_4, d_1\}$ 。至此,对于分组1,通过上述方法可以将分组结果转为3个训练任务: $Task1 = \{c_1, c_2, c_3, c_4\}$ , $Task2 = \{c_1, c_2, c_3\}$ , $Task3 = \{c_1, c_2, c_3, c_4, d_1\}$ 。

### 3.2 基于元学习的前端网络权重优化策略

在变电设备缺陷图像检测模型中,前端网络的核心功能是学习如何提取图像的底层纹理特征。然而,在面对包含新类别小样本缺陷检测问题中,前端网络的权重训练存在2个困难:一方面,由于学习样本过少,传统的模型训练策略很容易让模型在训练过程中陷入过拟合状态,而且由于测试样本过少,模型的过拟合甚至难以察觉;另一方面,传统的训练策略在执行每个训练任务时都会直接修改公共的前端网络,无论采用交替训练还是同步训练方式,都会因为不同任务的训练难度不同造成模型收敛困难。

结合上述分析及MAML模型的相关思想,本文提出了一种基于元学习的前端网络权重优化策略(meta learning-based fore-end weight optimization, ML-FWO)如图6所示。该策略的核心思想在于放缓模型训练过程中的梯度反馈速度,使得模型可以综合其在多个小样本缺陷检测任务上的表现后,再决定最终的梯度更新方向,从而提升模型对于小样本缺陷的检测能力。




图6 基于元学习的前端网络权重优化策略(ML-FWO)

Fig. 6 Front-end network weight optimization strategy based on meta-learning(ML-FWO)

ML-FWO的具体实现过程如图7所示,主要包含如下步骤。

#### 1) 生成训练任务

准备所需要的缺陷检测数据集,并对数据集中的缺陷进行分组,根据3.1节所设计的基于语义信息的元学习任务生成策略,由分类的组别生成相应的训练任务。




图 7 ML-FWO 模型训练过程

Fig. 7 Training process of ML-FWO

2) 搭建初始模型

在搭建初始模型时,采用本文作者团队提出的分散式缺陷检测网络结构<sup>[28]</sup>,网络结构如图 8 所示,网络参数说明如表 2 所示。由图 8 可知,模型主要由负责公共特征提取的前端网络和负责对各个组内目标进行特征融合分散式后端检测网络两部分组成。下面分别对其构成和功能进行介绍。

前端网络: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<sup>[29]</sup> 搭建了负责提取各类缺陷图像底层公共特征的前端网络,前端网络的具体结构如图 8 所示。在输入缺陷图像后对其进行多次卷积、池化以及张量拼接操作。此外,为了应对输入图像中目标的尺寸变化问题,前端网络会输出 3 种不同




图 8 分散式缺陷检测网络结构

Fig. 8 Decentralized defect detection network structure

表 2 分散式网络参数

Table 2 Parameters of the decentralized defect detection network

| 网络名称 | 层名称             | 具体说明                                                                                      | 备注                                                                                                          |
|------|-----------------|-------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------|
| 前端网络 | Focus           | /                                                                                         | /                                                                                                           |
|      | BaseConv (BC)   | 二维卷积+批量标准化+SiLU 激活函数                                                                      | 卷积核( $k$ )尺寸为 3 时,步长( $s$ )为 2,填充尺寸为 $\lfloor (k-s) \times 0.5 \rfloor$ ( $\lfloor \cdot \rfloor$ 为向下取整,下同) |
|      | MaxPooling (MP) | 二维最大值池化                                                                                   | 卷积核( $k$ )尺寸为 1 时,步长为 1,无填充                                                                                 |
|      | Concat          | $w \times h \times c_1 + w \times h \times c_2 \rightarrow w \times h \times (c_1 + c_2)$ | 默认池化尺寸( $k$ )为 3,步长为 1,填充尺寸为 $\lfloor (k-s) \times 0.5 \rfloor$                                             |
|      | 上采样层            | /                                                                                         | 默认上采样比例为 2,填充模式为就近填充                                                                                        |
| 后端网络 | BaseConv (BC)   | 二维卷积+批量标准化+SiLU 激活函数                                                                      | 卷积核( $k$ )尺寸为 3,步长为 1,填充尺寸为 $\lfloor (k-s) \times 0.5 \rfloor$                                              |
|      | Concat          | $w \times h \times c_1 + w \times h \times c_2 \rightarrow w \times h \times (c_1 + c_2)$ | /                                                                                                           |



尺寸的特征图,以便提取出不同尺度的图像局部特征。

后端网络:在得到前端网络输出的 3 个不同尺寸的特征图后,需要对这些特征图在通道维度进行切分。首先根据各组内包含的缺陷类别数在总类别数中的占比,将前端网络输出的 3 个特征图分别按照通道数切分为数个子特征图,然后将归属于同一组的子特征图输入到对应的分散式子网络中,以便执行后续计算。子网络接收到对应的特征图后,从中对公共特征进行进一步的筛选融合,最终得到尺寸为  $(80/40/20) \times (80/40/20) \times 1$ 、 $(80/40/20) \times (80/40/20) \times 4$ 、 $(80/40/20) \times (80/40/20) \times C$  ( $C$  为该组包含的类别数)的组内目标置信度、边框预测、组内缺陷类别预测向量。

但为了与本文的元学习任务进行结合,需要对网络结构进行适当调整。由于在元学习任务中,初始模型生成的训练模型在各个训练任务内接触的缺陷类别语义信息相似,类别数也有所降低,不再需要通过多个分散式子网络来应对多个语义信息差距较大的类别。因此,初始模型的前端网络不再并联若干分散式子网络,而是仅串联一个后端网络,负责将前端网络获得的特征信息进行筛选融合以得到检测结果。这一简化一方面可以加快训练速度,另一方面也可以降低网络参数量,以降低模型在小样本学习中过拟合的风险。

### 3) 生成训练模型

以初始模型的权重为基准,为每个训练任务生成一个训练模型。在根据初始模型生成训练模型时,由于各个训练任务中包含的类别数不同,本文所采用的端到端目标检测模型的末端网络需要根据训练任务的类别数调整末端卷积层的通道数,因此本文所生成的训练模型需要根据不同的训练任务调整其网络结构。

具体生成策略为:首先复制初始模型结构,然后根据训练任务的类别数对末端网络进行调整后得到训练模型,接着将训练模型中的节点按照是否与初始模型对应节点结构一致进行划分。对于结构一致的节点,直接读取初始模型中对应节点的权重参数;对于不一致的节点的权重执行随机初始化。由于不一致节点的权重主要集中于模型后端的类别预测模块,这一生成策略不会影响对于前端网络的优化效果。

### 4) 执行内循环过程

将各个训练模型投入训练任务中,根据各个训练任务所提供的训练样本进行若干轮次的迭代训练。在对各个训练任务生成对应的训练模型后,训练模型将根据训练任务的支持集数据进行深度学习训练,在读入样本图像后,模型通过逐层计算得到预测向量,根据模型预测结果与真实标签数据计算模型的预测损失。模型的预测输出为置信度预测向量  $\mathbf{p}^{\text{obj}}$ 、类别预测向量  $\mathbf{p}^{\text{cls}}$  以及边框预测向量  $\mathbf{p}^{\text{reg}}$ 。

采用交叉熵损失函数计算模型输出的置信度预测损失与类别预测损失。

模型输出的置信度预测损失与类别预测损失计算公式如下所示:

$$Loss_{\text{obj}} = - \sum_{i=1}^m (y_i^{\text{obj}} \log(p_i^{\text{obj}}) + (1 - y_i^{\text{obj}}) \log(1 - p_i^{\text{obj}})) \quad (1)$$

$$Loss_{\text{cls}} = - \sum_{i=1}^m \sum_{c=1}^C (y_{i,c}^{\text{cls}} \log(p_{i,c}^{\text{cls}}) + (1 - y_{i,c}^{\text{cls}}) \log(1 - p_{i,c}^{\text{cls}})) \quad (2)$$

式中:  $Loss_{\text{obj}}$  为置信度损失函数;  $Loss_{\text{cls}}$  为类别预测损失函数;  $m$  为样本数;  $C$  为总缺陷类别数;  $y_i^{\text{obj}}$  为第  $i$  个样本的目标置信度标签;  $p_i^{\text{obj}}$  第  $i$  个样本的目标置信度预测结果;  $y_{i,c}^{\text{cls}}$  为表征第  $i$  个样本是否属于第  $c$  类的标签(属于为 1, 不属于为 0);  $p_{i,c}^{\text{cls}}$  为模型预测的第  $i$  个样本属于第  $c$  类的概率。

目标检测模型的边框回归向量  $\mathbf{p}^{\text{reg}}$  一般可以写成  $(x_c, y_c, w, h)$ , 分别对应矩形预测框的中心点横纵坐标以及预测框的宽高。采用完全交并比 (complete intersection over union, CIoU) 损失函数计算预测框损失。CIoU 的计算需要以 IoU 为基础, IoU 损失原理是计算预测框和标签框之间的重叠面积, 通过预测框和标签框之间的交集比上预测框和标签框之间的并集以此来表征预测框和标签框之间的接近程度。IoU 损失计算公式如下:

$$IoU(A, B) = \frac{A \cap B}{A \cup B} \quad (3)$$

$$Loss_{\text{reg}} = 1 - IoU \quad (4)$$

式中: 假设  $A$  框为预测框;  $B$  框为标签框。

CIoU 的计算在 IoU 的基础上引入了中心点距离损失用于评估预测框与目标框中心点距离, 引入了边框宽高比差异损失用以评估预测框与目标框的大小差异。

中心点距离损失 (center distance, CD) 计算公式如下:

$$CD = \frac{d^2}{c^2} \quad (5)$$

式中:  $d$  为两个边框的中心距离;  $c$  为两个边框的远端对角连线长度。

边框宽高比差异损失  $v$  计算公式如下:

$$v = \frac{4}{\pi^2} \left( \arctan\left(\frac{w_{gt}}{h_{gt}}\right) - \arctan\left(\frac{w}{h}\right) \right)^2 \quad (6)$$

式中:  $w_{gt}$  和  $h_{gt}$  分别为真实边框的宽高;  $w$  和  $h$  为预测边框的宽高。

在以上计算指标的基础上, 可以得到 CIoU 损失计算公式如下:

$$Loss_{\text{reg}} = 1 - IoU + CD + \frac{v^2}{1 - IoU + v} \quad (7)$$

模型的总的损失函数是边框预测损失、置信度预测损失与类别预测损失的加权求和,如下式所示:

$$Loss = \omega_1 Loss_{reg} + \omega_2 Loss_{obj} + \omega_3 Loss_{cls}$$
 (8)

式中:  $\omega_1 \sim \omega_3$  为不同损失函数的权重。

完成训练模型在该训练任务的损失计算后,使用误差反向传播算法更新模型权重,重复若干轮次,即可完成 1 次内循环过程。

5) 执行外循环过程

所有的内循环训练任务执行完成后,计算模型在各个训练任务中的查询集损失,收集汇总后得到综合任务损失。根据综合任务损失对初始模型进行误差反馈,从而更新初始模型的模型参数。与 3) 类似,由于训练模型与初始模型的网络结构不完全相同,在执行误差反馈时,依旧将训练模型中的节点按照是否与初始模型对应节点结构一致进行划分。对于结构一致的节点,根据训练模型的训练任务得到反馈梯度对该节点进行权重更新;对于不一致的节点权重不做调整。由于不一致节点的权重主要集中于模型后端的类别预测模块,这一权重更新策略不会影响对于前端网络的权重优化。

6) 重复步骤 3) 和 5) 至初始模型在各个任务上的综合损失不再下降,模型训练完成。

3.3 面向小样本测试任务的模型微调策略

在完成公共特征提取网络优化训练完成后,初始模型的前端网络即可用于对变电设备缺陷图像的底层特征提取。在面对新的测试任务时,本文提出一种面向小样本测试任务的模型微调策略如图 9 所示,在保持前端网络权重不变的前提下,根据测试任务的检测类别数重构网络,并将模型投入到图 4 中设置的测试任务样本集进行最后的微调训练,使得训练完成后的模型可以在测试任务中有较好的表现。




图 9 面向测试任务的模型微调过程

Fig. 9 Model fine-tuning process for testing tasks

本文 3.2 节所提出的 ML-FWO 通过双循环训练策略提升模型在面对不同小样本训练任务时的综合检测能力。在面对新的检测任务时,通过继承优化完成后的公共特征提取算子,新搭建的测试任务模型具备较强的变电设备缺陷特征提取能力,对其进行微调训练可以保证模型的稳定收敛。此外,由于该模型微调策略主要针对

模型的后端网络,网络权重和计算量远小于前端,对其进行微调训练的计算量较低,可以保证模型的快速收敛。

4 实验分析

4.1 实验参数设置

1) 实验样本选取

采用本文作者团队构建的变电设备缺陷图像数据集<sup>[28]</sup>,根据数据集中各类缺陷的样本数量,按照图 4 划分方式对数据集进行分割,结果如表 3 所示。对于样本充裕类别,本文对每个类别各选 20 张包含该类缺陷的图像作为训练任务的支持集,另选 5 张图像作为查询集。对于样本欠缺类别,本文对各个类别各选取 5 张图像作为测试任务的支持集,另选 5 张作为查询集。

表 3 变电设备缺陷图像数据集缺陷样本分布

Table 3 Distribution of defect samples in the defect image dataset of substation equipment

| 切分类型   | 类别名称                 |
|--------|----------------------|
| 样本充裕类别 | 表计:表盘模糊,盖板破损,未穿安全帽   |
|        | 渗漏油:地面油污,绝缘子破裂       |
|        | 异物:挂空悬浮物,开关柜:压板分     |
|        | 呼吸器:硅胶变色             |
|        | 异物:鸟巢,表计读数异常,吸烟,未穿工装 |
| 样本欠缺类别 | 表计:表盘破损,箱门闭合异常       |
|        | 油位状态:油封异常,呼吸器:硅胶桶破损  |
|        | 表计:外壳破损              |

2) 训练任务生成

采用基于语义信息距离的分组策略对变电运维缺陷图像进行分组,并根据该结果对样本充裕类别进行分组,结果如表 4 所示。对分组结果进行分析可知,分组结果存在较高的合理性,例如:第 1 组中的类别均与表计相关,而第 4 组中的缺陷均与工作人员有关。

表 4 样本充裕类别分组

Table 4 Category grouping of abundance samples

| 组别序号 | 缺陷类别名称                              |
|------|-------------------------------------|
| 1    | 表计:表盘模糊,表计读数异常,<br>表计:表盘破损          |
| 2    | 盖板破损,渗漏油:地面油污,绝缘子破裂,箱门闭合异常          |
| 3    | 异物:挂空悬浮物,异物:鸟巢,<br>呼吸器:硅胶变色,开关柜:压板分 |
| 4    | 未穿工装,吸烟,未穿安全帽                       |



在此基础上,根据本文所提出的基于语义信息距离的任务生成策略所生成的 12 个训练任务中包含的类别如表 5 所示。

| 表 5 训练任务缺陷类别分配                                       |    |                                            |
|------------------------------------------------------|----|--------------------------------------------|
| Table 5 Defect category assignment for training task |    |                                            |
| 组别                                                   | 任务 | 缺陷类别名称                                     |
| 序号                                                   | 序号 |                                            |
| 1                                                    | 1  | 表计:表盘模糊,表计读数异常<br>表计:表盘破损                  |
|                                                      | 2  | 表计:表盘模糊,表计:表盘破损                            |
|                                                      | 3  | 表计:表盘模糊,表计读数异常<br>表计:表盘破损,箱门闭合异常           |
| 2                                                    | 1  | 盖板破损,渗漏油;地面油污,绝缘子破裂,箱门闭合异常                 |
|                                                      | 2  | 盖板破损,渗漏油;地面油污,绝缘子破裂                        |
|                                                      | 3  | 盖板破损,渗漏油;地面油污,绝缘子破裂,箱门闭合异常<br>开关柜;压板分      |
| 3                                                    | 1  | 异物:挂空悬浮物<br>异物:鸟巢<br>呼吸器:硅胶变色<br>开关柜;压板分   |
|                                                      | 2  | 异物:挂空悬浮物,异物:鸟巢,呼吸器:硅胶变色                    |
|                                                      | 3  | 异物:挂空悬浮物,异物:鸟巢,呼吸器:硅胶变色,<br>开关柜;压板分,箱门闭合异常 |
| 4                                                    | 1  | 未穿工装,吸烟,未穿安全帽                              |
|                                                      | 2  | 未穿工装,未穿安全帽                                 |

4.2 超参数选取

本章所提出的基于元学习的变电设备小样本缺陷图像检测模型在训练过程中包含若干超参数,为了选取合适的超参数,开展了如下超参数选取实验。

1) 内循环训练次数选取实验

在 3.2 节提出的双循环前端网络训练架构中,为了确定模型在内循环过程中的最优训练轮次,执行超参选取实验如下:在保持其他训练参数完全相同的前提下,分别设置训练任务中内循环的训练轮次为 1、3、5,即:初始模型投入训练任务后,在支持集上分别迭代 1、3、5 轮后,将其放入查询集内计算损失及反馈梯度。收集训练模型在各个训练任务中的反馈梯度,以此来更新初始模型权重。在执行相同轮次的外循环以及微调训练轮次后,测试成型模型的检测精度结果如表 6 所示。由表 6 可知,随着内循环训练轮次的提升,模型的检测精度显著下降。本文认为,出现这一现象的根本原因在于,随着内循环训练轮次的提升,训练模型与初始模型权重差异过大,从而影响了外循环的训练效果。

| 表 6 内循环轮次超参实验结果                                                         |                  |
|-------------------------------------------------------------------------|------------------|
| Table 6 Hyperparameter experiment results of internal circulation round |                  |
| 内循环训练轮次/轮                                                               | 成型模型 mAP@ 0. 5/% |
| 1                                                                       | 67. 72           |
| 3                                                                       | 60. 73           |
| 5                                                                       | 51. 91           |

2) 支持集各类样本数

在综合考虑变电设备小样本缺陷检测需求后,本文将模型训练任务查询集的各类样本数设为 5 张,测试任务中支持集与查询集的各类样本数也设为 5 张。而后,在保持其他训练参数完全相同的前提下,分别设置训练任务支持集中各类样本数为 100、50、20、10、5 张,生成对应的训练任务集。将初始模型投入到各个训练任务后执行相同轮次的训练与微调过程,测试成型模型的检测精度,实验结果如表 7 所示。由表 7 结果可知,训练样本过少会导致模型难以在各个训练任务中学习到缺陷类别的有效特征,进而严重影响模型性能,甚至导致模型因为样本过少而在迭代过程中发散。然而,模型的检测精度并非随着训练样本数的增加而线性递增。当样本数为 50 张时,模型的整体性能并没有显著提升,而当样本数增加到 100 张时,模型的检测精度反而有一定程度的下降。推测造成这一现象的原因有二:一方面,随着各类缺陷样本数增加,训练好的模型逐渐具备了提取各类缺陷核心特征的能力,此时,即使样本数进一步增加,模型的性能也不会有显著提升;另一方面,样本数的增加导致训练任务与小样本测试任务的差异性不断拉大,在训练任务上迭代收敛的成型网络难以适应测试任务,进而影响了模型性能。综上,本文将训练任务支持集中的各类样本数设为 20 张。

| 表 7 训练任务支持集样本数超参实验结果                                                            |                  |
|---------------------------------------------------------------------------------|------------------|
| Table 7 Hyperparameter experiment results of support data size in training task |                  |
| 训练任务支持集<br>各类样本数/张                                                              | 成型模型 mAP@ 0. 5/% |
| 100                                                                             | 64. 78           |
| 50                                                                              | 65. 87           |
| 20                                                                              | 67. 72           |
| 10                                                                              | 59. 19           |
| 5                                                                               | 模型不收敛            |

3) 训练任务数目

本文所提出的基于语义信息的训练任务生成策略通

过计算类别间的语义信息距离对类别进行分组,在分组结果的基础上对每个组别生成 3 个训练任务。为了验证此任务生成策略的有效性,开展如下实验:

在保证其他参数完全相同的前提下,基于表 4 的分组结果对每个组别分别生成 1、2、3、4 个训练任务,其中对每个组别生成 3 个训练任务的过程已经在 3.1 节中详细阐述,下面对其他几种任务生成策略进行介绍:每个组别生成 1 个任务:每个组别仅生成基准任务(基准任务的定义见 3.3 节);每个组别生成 2 个任务:每个组别生成 1 个基准任务,然后添加 1 个与该组别中心距离最近的非该组类别生成 1 个拓展任务;生成 5 个任务:每个组别生成 1 个基准任务,然后去除 1 个距离该组别中心最远的类别生成拓展任务 1,添加 1 个与该组别中心距离最近的非该组类别生成 1 个拓展任务 2,添加 2 个与该组别中心距离最近的非该组类别生成 1 个拓展任务生成拓展任务 3。

按照上述方法生成各组训练任务后,选取相同数量的支持集与查询集样本构成数据集。将初始模型分别投入到各组训练任务中执行相同轮次的训练过程与微调过程,测试成型模型的检测精度,结果如表 8 所示。结果显示,本文所提出的对每个类别分组生成 3 个训练任务的训练策略所得模型精度最高。训练任务较少时,模型难以在训练任务中学习到有效特征;而当训练任务较多时,模型的性能并未显著提升,因为在训练任务充裕后,进一步增加训练任务数并不能丰富训练任务类型,反而会带来较高的计算开支。

| 表 8 训练任务数超参实验结果                                                   |                           |                   |
|-------------------------------------------------------------------|---------------------------|-------------------|
| Table 8 Hyperparameter experiment results of training task number |                           |                   |
| 训练任务组别                                                            | 任务描述                      | 成型模型<br>mAP@0.5/% |
| 训练任务组 1                                                           | 每个类别分组生成 1 个任务,共 4 个训练任务  | 60.77             |
| 训练任务组 2                                                           | 每个类别分组生成 2 个任务,共 8 个训练任务  | 64.87             |
| 训练任务组 3                                                           | 每个类别分组生成 3 个任务,共 12 个训练任务 | 67.72             |
| 训练任务组 4                                                           | 每个类别分组生成 4 个任务,共 16 个训练任务 | 67.22             |

4.2 结果分析

在训练过程中本文所采用的软硬件平台参数如表 9 所示,训练过程中使用 Adam 优化器,不同训练过程的相关训练参数设置如表 10 所示。

| 表 9 软硬件平台参数                                       |                             |
|---------------------------------------------------|-----------------------------|
| Table 9 Software and hardware platform parameters |                             |
| 软硬件平台                                             | 型号参数                        |
| 操作系统版本                                            | Ubuntu 18.04.5 LTS          |
| CPU                                               | Intel(R) Xeon(R) Gold 6226R |
| GPU                                               | NVIDIA Geforce RTX 3090     |
| 深度学习框架                                            | PyTorch 1.12.0 + cuda 11.6  |

| 表 10 优化器参数设置                                  |                    |                      |
|-----------------------------------------------|--------------------|----------------------|
| Table 10 Settings of the optimizer parameters |                    |                      |
| 训练过程                                          | 参数设置               |                      |
|                                               | 学习率                | Weight decay         |
| 内循环训练过程                                       | $1 \times 10^{-4}$ | $7.5 \times 10^{-4}$ |
| 外循环训练过程                                       | $1 \times 10^{-4}$ | $1 \times 10^{-4}$   |
| 测试任务微调训练                                      | $1 \times 10^{-3}$ | $1 \times 10^{-5}$   |

1) 训练损失分析

本文所提出的模型优化策略在训练过程中主要分为 2 个部分:前端网络优化训练以及测试任务微调训练。图 10、11 分别展示了模型在 2 个训练阶段中支持集与查询集的损失下降情况,下面将分别对其进行分析。




图 10 前端网络优化训练损失  
Fig. 10 Training loss of front-end network optimization

(1) 前端网络优化训练损失

图 10 展示了模型在前端网络优化训练过程中的损失下降情况,图内记录的“平均支持集/查询集损失”计算方式如下:

$$Loss^{sp} = \sum_{i=1}^T loss_i^{sp} \tag{9}$$

$$Loss^{qr} = \sum_{i=1}^T loss_i^{qr} \tag{10}$$

式中: $loss_i^{sp}$  表示模型在第  $i$  个训练任务中支持集上的训练损失; $loss_i^{qr}$  表示模型在第  $i$  个任务上的查询集损失;




图 11 后端模型微调训练损失

入 ML-FWO 优化模型权重后,模型精度提升了 5.59%。进一步,使用本文所提出的 SI-MLTG 替换随机任务生成策略,模型的精度进一步提升了 1.74%。在对初始模型同时使用 ML-FWO 与 SI-MLTG 后,模型的最终精度提升了 7.33%,效果显著。

表 11 消融实验结果

Table 11 Results of ablation experiments

| 模型名称   | 模型描述                | 参数量  | mAP     | 检测     |
|--------|---------------------|------|---------|--------|
|        |                     | /M   | @ 0.5/% | 速度/fps |
| 初始模型   | 初始模型                | 17.2 | 60.39   | 20.3   |
| 改良模型 1 | 初始模型+ML-FWO         | 17.2 | 65.98   | 20.4   |
| 改良模型 2 | 初始模型+ML-FWO+SI-MLTG | 17.2 | 67.72   | 20.4   |

$Loss^{sp/qr}$  即为图 10 中的“平均支持集/查询集损失”。

由图 10 可知,在通过内外双循环的方式优化模型的前端网络时,模型在支持集与查询集上的训练损失均在缓慢下降至收敛,但是收敛后的损失值差异较大,模型在支持集上的损失大约是查询集的 3 倍。造成这一现象的根本原因在于:在执行内外双循环过程对模型进行权重优化时,分配给各个训练任务的训练模型由初始模型生成,而初始模型的权重参数通过外循环反馈的梯度进行更新学习,这些梯度信息是通过计算模型在查询集上的训练损失得到的。初始模型的更新梯度只受到各个训练模型在查询集上所得损失的影响,不受训练模型在支持集上训练损失影响。随着外循环的不断进行,查询集上的反馈梯度不断累积,使得初始模型产生的各个训练模型可以不断降低其在查询集上的损失,但不会降低训练模型在支持集上的训练损失。

出现这一过程也是将 MAML 引入缺陷检测网络后出现的必然现象。本文引入 MAML 思想对变电设备缺陷检测模型进行优化的根本目的是为了提升模型对于小样本任务的泛化能力。在深度学习模型的训练中,模型的泛化能力由其接触新样本时的预测损失表征。本文所构建训练任务中的查询集不参与内循环过程中训练模型的梯度迭代,因此,模型在查询集上的训练损失越低,代表模型的泛化性能越好。

(2) 后端网络微调训练损失

模型在小样本测试任务的微调训练过程中的测试任务损失如图 11 所示,由图可知,模型在进行最终微调时起始的查询集损失远低于支持集损失。这一现象说明,经过 ML 优化的变电设备缺陷检测网络在在面对新的检测任务时具备较好的泛化能力。

2) 消融对照实验分析

对本文所提出的改良模型执行消融实验,模型整体精度变化如表 11 所示。由表 11 的实验结果可知:在引

表 12 和 13 分别展示了对样本充裕和样本欠缺的缺陷类别检测结果。结果显示,本文所提出的方法对于样本欠缺类别的精度提升效果更为显著。在没有引入 ML-FWO 时,初始模型对于样本欠缺类别的平均检测精度只有 44.52%,远低于测试任务总类别的平均精度均值 60.39%,这是因为样本欠缺类别包含的训练样本少,模型缺乏对于小样本数据的应对能力。引入 ML-FWO 后,模型对于样本欠缺类别的检测精度提升到了 52.40%,相

表 12 样本充裕类别各类缺陷检测精度

Table 12 Detection accuracy of various defects in the abundance category

| 切分类型   | 类别名称     | 模型检测精度 AP@0.5/% |        |        |
|--------|----------|-----------------|--------|--------|
|        |          | 初始模型            | 改良模型 1 | 改良模型 2 |
| 样本充裕类别 | 表计:表盘模糊  | 67.18           | 73.09  | 74.77  |
|        | 盖板破损     | 61.75           | 67.08  | 69.79  |
|        | 未穿安全帽    | 67.50           | 74.05  | 75.83  |
|        | 渗漏油:地面油污 | 61.00           | 65.30  | 64.72  |
|        | 绝缘子破裂    | 62.71           | 67.23  | 68.86  |
|        | 异物:挂空悬浮物 | 78.08           | 82.49  | 84.95  |
|        | 开关柜:压板分  | 54.18           | 59.08  | 60.81  |
|        | 呼吸器:硅胶变色 | 62.81           | 67.59  | 68.8   |
|        | 异物:鸟巢    | 63.24           | 70.56  | 71.02  |
|        | 表计读数异常   | 55.08           | 59.80  | 61.65  |
|        | 吸烟       | 55.96           | 59.78  | 61.42  |
|        | 未穿工装     | 71.47           | 76.11  | 77.32  |
|        | 表计:表盘破损  | 63.24           | 68.59  | 69.35  |
|        | 箱门闭合异常   | 68.87           | 73.70  | 73.94  |



表 13 样本欠缺类别各类缺陷检测精度

Table 13 Detection accuracy of various defects in the deficient categories

| 切分类型   | 类别名称       | 模型检测精度 AP@ 0. 5/% |        |        |
|--------|------------|-------------------|--------|--------|
|        |            | 初始模型              | 改良模型 1 | 改良模型 2 |
| 样本欠缺类别 | 油位状态;油封异常  | 43. 34            | 51. 30 | 54. 77 |
|        | 呼吸器;硅胶桶破损  | 42. 87            | 51. 13 | 55. 70 |
|        | 表计;外壳破损    | 47. 35            | 54. 78 | 57. 54 |
|        | 样本欠缺类别精度均值 | 44. 52            | 52. 40 | 56. 00 |

对于引入前提升了 7. 88%,明显高于引入 ML-FWO 前后的 mAP 增幅(5. 59%)。进一步,引入本文提出的基于语义信息的任务生成方式前后,样本欠缺类别的精度均值由 52. 40%增长到了 56. 00%,增长了 3. 60%,增幅也显著高于 mAP 的增幅(1. 74%)。上述实验结果表明:本文所提出的基于 MAML 的前端网络优化策略和基于语义信息的训练任务生成策略可以有效提升模型对于小样本类别的缺陷检测能力。

5 结 论

本文针对传统的基于海量数据训练的深度学习变电设备缺陷图像检测模型在实际应用中由于缺陷样本数量小,无法有效处理新增类别缺陷及稀少类别缺陷的问题,构建了一种基于元学习的变电设备小样本缺陷图像检测模型。该模型的核心创新点以及性能提升包括:

- 1)提出了一种基于语义信息的元学习训练任务生成策略 ( semantic information-based meta learning task generation,SI-MLTG)。将变电设备缺陷类别间的语义信息相似度作为训练任务生成的重要参考指标,使得生成的训练任务更接近真实变电运维场景,为元学习的进行提供了有较高泛化性和鲁棒性的任务集。实验结果表明,引入这种基于语义信息的任务生成方式前后,样本欠缺类别的精度均值由 52. 40%增长到了 56. 00%,增长了 3. 60%,增幅也显著高于 mAP 的增幅(1. 74%)。
- 2)提出了一种基于元学习的前端网络权重优化策略 ( meta learning-based fore-end weight optiminzation,ML-FWO),通过减缓模型训练过程中的梯度反馈速度,使得模型可以综合其在多个小样本缺陷检测任务上的表现后,再决定最终的梯度更新方向,从而提升模型对于包含新类别的小样本检测任务的应对能力。引入 ML-FWO 后,模型对于样本欠缺类别的检测精度提升到了 52. 40%,相对于引入前提升了 7. 88%,明显高于引入 ML-FWO 前后的 mAP 增幅(5. 59%)。

3)提出了一种面向小样本测试任务的模型微调策略,在保持前端网络权重不变的前提下,根据测试任务的检测类别数重构网络,并将模型投入到设置的测试任务样本集进行最后的微调训练,使得训练完成后的模型可以在测试任务中有较好的表现。同时由于该模型微调策略主要针对模型的后端网络,网络权重和计算量远小于前端,对其进行微调训练的计算量较低,可以保证模型的快速收敛。

本算法模型适用于缺陷样本数量小、常有新增缺陷类别出现的实际变电设备运维场景,未来可进一步研究该深度学习模型在边缘设备上的部署与应用策略。引入稀疏训练策略对现有的变电设备缺陷图像检测模型进行模块化剪枝,然后结合硬件情况引入深度可分离卷积与半精度数据计算策略降低模型的计算存储成本,从而降低模型的参数量,提升模型检测速度,使模型可以在实际变电运维场景中投入使用。

参考文献

[ 1 ] 刘义艳,郝婷楠,张伟. 融合 RMT 特征值的电网异常状态检测[J]. 电子测量与仪器学报,2023,37( 12 ): 242-252.

LIU Y Y, HAO T N, ZHANG W. Abnormal state detection of power system based on RMT eigenvalue fusion [ J ]. Journal of Electronic Measurement and Instrumentation, 2023,37( 12 ):242-252.

[ 2 ] 杨生鹏,文中,丁剑,等. 二次分解组合 LSTM 的短期风电功率预测模型[J]. 国外电子测量技术,2024,43(1):87-93.

YANG SH P, WEN ZH, DING J, et al. Short-term wind power prediction model for quadratic decomposition combined LSTM [ J ]. Foreign Electronic Measurement Technology, 2024,43( 1 ):87-93.

[ 3 ] 阳林,刘子其,孙夏青,等. 电力变压器关键尺寸视觉检测方法及其缩比模型验证[J]. 电子测量技术,2024,47( 4 ): 147-155.

YANG L, LIU Z Q, SUN X Q, et al. Visual inspection method for key dimensions of power transformers and its scaled model validation [ J ]. Electronic Measurement Technology, 2024,47( 4 ):147-155.

[ 4 ] 金字锋,陶重彝. 基于 Transformer 的融合信息增强 3D 目标检测算法[J]. 仪器仪表学报,2023,44( 12 ): 297-306.

JIN Y F, TAO CH B. Fusion information enhanced method based on transformer for 3D object detection[J]. Chinese Journal of Scientific Instrument, 2023,44( 12 ): 297-306.

[ 5 ] 胡霞,仲林林. 基于改进 R<sup>3</sup>det 的无人机电力杆塔倾斜程度检测[J]. 仪器仪表学报,2023,44( 10 ):

- 189-200.
- HU X, ZHONG L L. Incline detection of power towers from UAV images based on the improved R<sup>3</sup>det [J]. Chinese Journal of Scientific Instrument, 2023, 44(10): 189-200.
- [6] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: Optimal speed and accuracy of object detection[J]. ArXiv preprint arXiv:2004.10934, 2020.
- [7] 郭敬东, 陈彬, 王仁书, 等. 基于 YOLO 的无人机电力线路杆塔巡检图像实时检测[J]. 中国电力, 2019, 52(7): 17-23.
- GUO J D, CHEN B, WANG R SH, et al. Real time detection of UAV power line tower inspection image based on Yolo[J]. Electric Power, 2019, 52(7): 17-23.
- [8] 蓝金辉, 王迪, 申小盼. 卷积神经网络在视觉图像检测的研究进展[J]. 仪器仪表学报, 2020, 41(4): 167-182.
- LAN J H, WANG D, SHEN X P. Research progress on visual image detection based on convolutional neural network[J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 167-182.
- [9] 周景, 王满意, 田兆星. 基于多模态的缺陷绝缘子图像的多标签分类[J/OL]. 高电压技术, 1-11 [2024-08-20].
- ZHOU J, WANG M Y, TIAN ZH X. Multi-label classification of defective Insulator images based on multimodality[J/OL]. High Voltage Engineering, 1-11 [2024-08-20].
- [10] 廖才波, 黄智勇, 杨金鑫, 等. 基于缺陷文本识别的变压器风险评估及辅助检修决策方法[J]. 高电压技术, 2024, 50(7): 2931-2941.
- LIAO C B, HUANG ZH Y, YANG J X, et al. Risk assessment and intelligent auxiliary maintenance decision method of transformer based on defect text recognition[J]. High Voltage Engineering, 2024, 50(7): 2931-2941.
- [11] 律方成, 牛雷雷, 王胜辉, 等. 基于优化 YOLOv4 的主要电气设备智能检测及调参策略[J]. 电工技术学报, 2021, 36(22): 4837-4848.
- LYU F CH, NIU L L, WANG SH H, et al. Intelligent detection and parameter adjustment strategy of major electrical equipment based on optimized YOLOv4[J]. Transactions of China Electrotechnical Society, 2021, 36(22): 4837-4848.
- [12] LIU J SH, CUI G L, XIAO CH D. A real-time and efficient surface defect detection method based on YOLOv4[J]. Journal of Real-Time Image Processing, 2023, 20(4): 77.
- [13] 和敬涵, 罗国敏, 程梦晓, 等. 新一代人工智能在电力系统故障分析及定位中的研究综述[J]. 中国电机工程学报, 2020, 40(17): 5506-5516.
- HE J H, LUO G M, CHENG M X, et al. A research review on application of artificial intelligence in power system fault analysis and location[J]. Proceedings of the CSEE, 2020, 40(17): 5506-5516.
- [14] KOCH G, ZEMEL R, SALAKHUTDINOV R. Siamese neural networks for one-shot image recognition[C]. Deep Learning, 2015: 125-132.
- [15] VINYALS O, BLUNDELL C, LILLICRAP T, et al. Matching networks for one shot learning[C]. Proceedings of the 30th International Conference on Neural Information Processing Systems (NIPS'16), 2016: 3637-3645.
- [16] SNELL J, SWERSKY K, ZEMEL R. Prototypical networks for few-shot learning[C]. Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS'17), 2017: 4080-4090.
- [17] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks [C]. International Conference on Machine Learning, 2018: 1856-1868.
- [18] LI ZH G, ZHOU F W, CHEN F, et al. Meta-sgd: Learning to learn quickly for few-shot learning[J]. ArXiv preprint arXiv:1707.09835, 2017.
- [19] JAMAL M A, QI G J. Task agnostic meta-learning for few-shot learning [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 11711-11719.
- [20] JIANG X, HAVAEI M, CHARTRAND G, et al. On the importance of attention in meta-learning for few-shot text classification [J]. ArXiv preprint arXiv:1806.00852, 2018.
- [21] WANG X, HUANG T E, DARRELL T, et al. Frustratingly simple few-shot object detection[J]. 37 th International Conference on Machine Learning, 2021: 9919-9928.
- [22] SUN B, LI B H, CAI SH C, et al. FSCE: Few-shot object detection via contrastive proposal encoding[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 7348-7358.
- [23] ZHOU X F, YANG L, WANG X, et al. Two stages prompting for few-shot multi-intent detection [J]. Neurocomputing, 2024, 579: 127424.
- [24] SCHMIDHUBER J. Evolutionary principles in self-referential learning[D]. Technische Universität München, 1987.

[25] HINTON G E, PLAUT D C. Using fast weights to deblur old memories[C]. Proceedings of the 9th Annual Conference of the Cognitive Science Society, 1987: 177-186.

[26] SHEN ZH Y, ZHAO Q SH, LIU Y Y. MAML-SGD: A reliable airline rescheduling algorithm for small-sample learning based on MAML and SGD[J]. Journal of Supercomputing, 2024, 80(10):14953-14977.

[27] TIAN Y Y, ZOU Q, WANG CH Y, et al. MAMLCDA: A meta-learning model for predicting circRNA-disease association based on MAML combined with CNN[J]. IEEE Journal of Biomedical and Health Informatics, 2024, 28(7):4325-4335.

[28] 张鑫,叶俊杰,崔瑶,等. 基于语义信息距离解耦的变电运维多类别缺陷图像检测[J]. 中国电力,2023, 56(6):209-218.

ZHANG X, YE J J, CUI Y, et al. Decoupled semantic distance based multi-class defect scene detecting for substations[J]. Electric Power, 2023,56(6):209-218.

[29] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. Scaled-yolov4: Scaling cross stage partial network[C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021:13024-13033.

作者简介



仲林林 (通信作者),2012 年于西安交通大学获得学士学位,2017 年于西安交通大学和法国图卢兹第三大学获得博士学位,现为东南大学副研究员/博士生导师,主要研究方向为高电压技术、放电等离子体技术、人工智能技术。

E-mail: linlin@seu.edu.cn

**Zhong Linlin** (Corresponding author) received his B.Sc. degree from Xi'an Jiaotong University in 2012, and received his Ph.D. degree from Xi'an Jiaotong University and Université Toulouse III-Paul Sabatier in 2017. He is currently an associate professor and a Ph.D. advisor at Southeast University. His main research interests include the interdisciplinary study of high

voltage engineering, plasma engineering, and artificial intelligence.



吴奇,2022 年于湖南大学获得学士学位,现为东南大学硕士研究生,主要研究方向为人工智能技术在电力领域的应用。

E-mail: 220222676@seu.edu.cn

**Wu Qi** received his B.Sc. degree from Hunan University in 2022. He is currently a master student at Southeast University. His main research direction is the application of artificial intelligence technology in the field of electrical.



叶俊杰,2020 年于东南大学获得学士学位,2023 年于东南大学获得硕士学位,现就职于国网上海市电力公司,主要研究方向为人工智能技术在电力领域的应用。

E-mail: 806731385@qq.com

**Ye Junjie** received his B.Sc. degree from Southeast University in 2020 and M.Sc. degree from Southeast University in 2023. He is currently working at State Grid Shanghai Municipal Electric Power Company Urban Power Supply Company. His main research direction is the application of artificial intelligence technology in the electrical field.



高丙团,2002 年于哈尔滨工业大学获得学士学位,2004 年于哈尔滨工业大学获得硕士学位,2007 年于哈尔滨工业大学获得博士学位,现为东南大学教授/博士生导师,主要研究方向为非线性系统的建模与控制、机器人自动化、新能源发电与电力需求侧管理等。

E-mail: gaobingtuan@seu.edu.cn

**Gao Bingtuan** received his B.Sc. degree, M.Sc. degree, Ph.D. degree all from Harbin Institute of Technology in 2002, 2004, and 2007, respectively. He is currently a professor and Ph.D. advisor at Southeast University. His main research interests include modeling and control of nonlinear systems, robotics and automation, new energy power generation, and power demand side management.