

基于自监督学习的输电线路 螺栓螺母异常检测技术

杨景崙¹, 辛 巍¹, 刘 全², 刘晓华¹, 孙忠慧¹, 张治国¹,
刘文超¹, 王沐东¹, 付思诗¹

(1. 国网湖北省电力有限公司 超高压公司, 武汉 430050;

2. 浙江大学 滨江研究院, 杭州 310000)

摘要: 针对输电线路螺栓螺母异常检测问题, 对无标签螺栓数据训练深度学习预训练模型进行了研究, 首次采用了自监督学习的方法, 使用大量无标签数据集进行学习, 首先, 使用少量带标签的螺栓目标检测数据集训练目标检测模型, 推理获取大量的单图无标签螺栓数据集, 然后, 采用自监督学习方法通过单图无标签螺栓数据集训练螺栓预训练大模型并获取可视化的螺栓注意力图, 最后通过实验对比螺栓预训练大模型在螺栓分类和检索任务中与非预训练模型的效果, 实验结果表明无标签数据得到的预训练大模型可以注意到螺杆、螺母、连接件的位置, 进一步表明螺栓预训练大模型在分类任务中准确率提升了2%到7%, 在螺栓检索任务中平均精度提升了8%。

关键词: 自监督学习; 输电线路; 螺栓检测; 图像检索; 预训练

Fault Detection Technology of Bolts and Nuts based on Self-Supervised Learning in Transmission Line

YANG Jingyu¹, XIN Wei¹, LIU Quan², LIU Xiaohua¹, SUN Zhonghui¹,
ZHANG Zhiguo¹, LIU Wenchao¹, WANG Mudong¹, FU Sishi¹

(1. State Grid Hubei Extra High Voltage Company, Wuhan 430050, China;

2. Binjiang Institute of Zhejiang University, Hangzhou 310000, China)

Abstract: Aiming at the detection problem of bolts and nuts in transmission lines, an unlabeled bolt data training deep learning pre-training model is studied, a self-supervised learning method is adopted for the first time, a large number of unlabeled data sets are used to learn. Firstly, a small amount of labeled bolt object detection data sets are used to train the object detection model, inference and obtain a large number of single-image unlabeled bolt datasets, and then the self-supervised learning method is used to train the bolt pre-training large model through the single-image unlabeled bolt dataset and obtain the visualized bolt attention map. Finally, the effects of the bolt classification and retrieval tasks on the bolt pre-training large model are compared by the experiment with the non-pre-trained model. The experimental results show that the pre-trained large model obtained from unlabeled data sets can notice the positions of screws, nuts, and connectors, which further shows that the accuracy of the bolt pre-trained large model in the classification task is improved by 2% to 7%, and the average accuracy by 8% in the bolt retrieval task.

Keywords: self-supervised learning; transmission lines; image classification; image retrieval; pre-training

0 引言

电力供应是生产生活的重要保障。我国输电线线路众多, 覆盖广泛, 因此基层巡检、运维成本都面临着极大的挑战, 迫切需要一种自动化与智能化检测技术来改变这一现状^[1-2]。近年来, 越来越多的研究尝试将人工智能应用于电力设备的运维以期达到高通量检测、自动化筛选故障点用以提高检测效率、降低运维成本^[3]。主要使用计算机视觉算法来分析输电线路航拍图像, 以识别图像中关键部件

的缺陷类型并进行准确定位作为目标。目前, 如何对输电线路关键部件视觉缺陷进行准确检测仍是关键问题之一^[4-5]。其中, 在输电线路中用于固定、连接的螺栓部件在人为或者环境的影响下经常会出现螺栓损坏故障, 轻则引发输电线路部分组件脱落的故障, 重则引发重大电网事故^[6-7], 因此对输电线路中螺栓检测对于输电线路运维具有重大意义。

输电线路螺栓故障检测技术主要是将计算机视觉算法

收稿日期: 2023-01-03; 修回日期: 2023-02-10。

作者简介: 杨景崙(1995-), 男, 湖北武汉人, 硕士, 助理工程师, 主要从事输电线路运维相关工作方向的研究。

通讯作者: 刘 全(1991-), 男, 浙江杭州人, 硕士, 高级工程师, 主要从事人工智能算法方向的研究。

引用格式: 杨景崙, 辛 巍, 刘 全, 等. 基于自监督学习的输电线路螺栓螺母异常检测技术[J]. 计算机测量与控制, 2023, 31(5): 87-93.

做为技术基础, 输电线路无人机巡检图像作为待检测对象, 以识别图像中螺栓缺陷目标^[8]。基于深度学习的目标检测模型目前是处理输电线路巡检图像的最优选择^[9]。为了将深度学习模型用于输电线路关键部件缺陷检测, 首先需要构建完备的关键部件缺陷数据集用于训练和测试。在无人机将航拍图像传回之后, 使用数据集训练搭建好的深度学习模型即可完成各类缺陷检测任务^[10]。

对于输电线路螺栓检测方法, 主要依靠无人机巡检技术、图像处理、深度学习的图像识别技术实现螺栓检测。检测流程通过无人机对输电线路巡检, 获得输电线路的高清图像, 再通过人工或图像处理等方式对无人机巡检图像中的螺栓进行检查^[11-14]。近几年, 随着深度学习技术和无人机技术的快速发展。有监督学习的目标检测被广泛应用到螺栓检测任务中。通过 SSD^[15] 和 YOLOv3^[16] 目标检测模型对螺栓进行有监督学习, 先对关键挂点部位进行有监督学习, 再对挂点中的螺栓目标进行有监督学习, 同时依靠数据增强方法, 提高了螺栓检测的准确率。利用 AdaBoost 和与或图基于 Haar 特征建立螺栓开口销分类器, 但是这种方法对螺栓角度和亮度变化鲁棒性差^[17]。通过有监督学习训练两次特征金字塔分别提取可能螺栓缺失开口销的区域和螺栓缺失开口销的区域, 再通过 DBSCAN^[18] 对螺栓销钉缺失进行目标检测。使用基于注意机制的弱监督螺栓检测模型^[19], 提升了螺栓检测的精度。应用知识图谱和知识特征融合方法提升螺栓和螺母分类任务的准确率和召回率^[20]。

但是, 由于目前螺栓故障检测技术仍不能保证具有较高的识别准确率, 故该工作主要采用计算机视觉螺栓故障检测技术辅助加人工复检, 人工复检工作量仍然很大。目前在所有关于输电线路螺栓检测的研究主要中存在三点问题。第一, 所有研究均使用少量的有标签的自建数据集进行螺栓检测相关任务的有监督学习和验证。第二, 少量的标注数据导致了大量的巡检原始数据没有被模型学习, 造成了训练数据集资源的浪费。第三, 若对大量的原始数据进行标注, 需要花费极大的时间和人力成本才能完成这一项漫长而又艰巨的标注任务^[19]。

针对以上输电线路螺栓检测有监督学习通常依赖大量标注数据以达到较好的性能的问题。本文采用自监督学习方法从大量的无标签螺栓数据中获取螺栓信息有很大价值。自监督学习通过学习大量无标签数据的内存在特征, SimCLR^[21] 和 MoCo^[22-24] 自监督学习通过拉大不同样本之间的距离实现和缩小同一样本内的距离, 学习数据集的内在特征实现自监督学习。该方法需要需要保证数据集中不同类别数据量的均衡, 但是对于螺栓异常检测负样本是极少的。直到 BYOL^[25] 自监督学习方法的出现, 不再需要数据均衡, 可以学习数据分布及内在特征。该方法对于螺栓检测样本及不均衡的场景十分适用。最近, 最先进的自监督学习框架 DINO^[26] 基于 BYOL 方法和先进的视觉 Transformer^[27] 主干网络在大模型预训练任务中展现出了很好的

表现。

本文针对数据集资源浪费的问题, 为了充分利用无标签的螺栓数据集资源, 首次提出使用自监督学习进行螺栓检测大模型预训练方法, 并验证自监督学习在螺栓检测预训练的效果。首先通过有监督学习目标检测方法获得 115 万张无标签螺栓数据。然后使用无监督学习的方式预训练螺栓检测大模型。最后通过预训练大模型生成螺栓注意力图, 验证了自监督学习在螺栓大模型预训练中可以有效学习到有效的螺栓特征。

为了验证预训练大模型在螺栓检测任务中的效果, 建立了螺栓分类任务数据集和螺栓图像检索数据集。通过下游任务的有监督学习, 验证了自监督螺栓预训练大模型, 在螺栓分类任务和螺栓图像检索任务中效果优于传统的有监督学习。

总之, 本文在螺栓检测领域主要有 4 个方面的贡献: 1) 证明了使用大量无标注螺栓图像数据集的自监督学习在输电线路螺栓、螺母异常检测中是有效的。2) 实验结果表明该方法在下游螺栓状态分类任务和螺栓图像检索任务中都有很好的表现。3) 实验结果对比了各种计算机视觉结构, 显示了 ViT 在螺栓异常检测中的优越性, ViT-B/8 在分类任务中表现最好, ViT-S/8 在检索任务中由于 ResNet50。4) 展示了模型在自监督学习过程中学习到的螺栓特征。

1 研究思路

该研究根据输电线路原始数据特点和自监督学习方法对输电线路螺栓螺母检测方法进行设计。首先获取螺栓数据集, 包括螺栓原始数据集、单图无标签螺栓数据螺栓分类数据集、螺栓图像检索数据集。然后使用自监督学习 DINO 训练螺栓预训练大模型。最后验证该算法在螺栓迁移学习和螺栓图像检索任务中的有效性。

螺栓数据集获取包括原始数据的采集, 为了使自监督模型学习到更广泛的螺栓场景, 充分利用所能获取的输电线路螺栓数据, 通过标注少量的螺栓目标检测数据集, 使用 Yolo 训练螺栓目标检测模型, 用于提取单图无标签螺栓数据。使用 Yolo 模型推理出大量单图无标签螺栓数据用于自监督学习大模型训练。螺栓分类数据集、螺栓图像检索数据集分别用于验证自监督预训练模型在螺栓分类任务和螺栓检索任务的有效性。DINO 是目前表现最好的自监督学习方法, 首次获取无标签螺栓数据集在自监督模型上训练螺栓预训练大模型。

因此本文的研究思路是基于自监督学习的输电线路螺栓螺母检测算法, 实现螺栓检测大模型的训练, 并提升算法的准确率。

2 螺栓检测自监督学习算法

2.1 螺栓数据集获取

2.1.1 原始数据集来源

本文采用的原始数据集有 3 个来源, 分别为中国电网

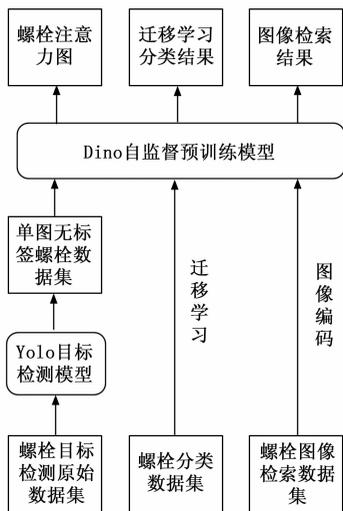


图 1 算法整体研究流程

公司提供的真实输电线路无人机巡检图像、输电线路人工采集图像和输电线路零件图像。输电线路无人机巡检图像是使用像素为 2 000 W、焦距为 8.8 mm、光圈为 $f/3.2$ 的高清摄像机在距离输电线路塔 1.5~3 m 的距离上拍摄的像素大小为 547 236 48 的输电塔图像。采用无人机定点巡航或人工飞行无人机进行拍摄。每个输电塔用固定拍摄位置, 主要对地线挂点、绝缘子上挂点、绝缘子下挂点进行拍摄。拍摄距离在 1.5~3 m 之间。输电线路人工采集图像是将输电线路各部件组装, 人工制造模拟不同的螺栓状态进行拍摄的图像。拍摄相机参数与无人机巡检图像保持一致。首先将绝缘子下挂点和底线挂点悬挂在空中, 模拟实现螺栓状态多种状态, 包括螺栓松动、螺栓平扣、螺栓欠扣、缺螺母等状态。然后由人工手持无人机模拟无人机飞行。最后在一组固定点位进行拍摄, 点位分别为间隔角度为 30 度, 和上、中、下 3 个视角进行拍摄。一组螺栓图像为 36 张图像。拍摄时间包括造成、中午、傍晚, 模拟了不同光照角度的信息。拍摄天气为自然天气, 包括晴天、阴天、小雨天气, 增加了天气对检测数据信息。输电线路零件图像是将多个包含螺栓的输电线路零部件摆放在一起进行拍摄的图像。拍摄方法与输电线路人工采集图像方法相同。



图 2 输电线路螺栓原始数据, 真实的输电线路无人机巡检图像(左)、输电线路人工采集图像(中)、输电线路零部件图像(右)

真实的输电线路无人机巡检图像可以保留数据的实际应用场景信息, 输电线路人工采集图像和输电线路零部件

图像通过模型不同的螺栓状态、拍摄角度、自然环境的光照强度丰富了螺栓的数据信息, 并添了一定的噪音, 可以适当的环境模型学习过程的过拟合现象。

从原始图像中获得单独的螺栓图像用于自监督学习, 本文使用目标检测模型从原始数据集检测螺栓图像。首先通过人工标注的方式, 在原始图像为 3 通道的 RGB 图像 $i \in R^3 \times H_0 \times W_0$ 中使用矩形框将螺栓标注。然后训练一个螺栓的目标检测模型, 本文采用 Yolo^[28-30] 进行训练。最后对原始数据进行推理, 从原始数据中裁剪出所有检测到的螺栓。Yolo 的网络结构主要由 4 个部分构成, 分别为输入端、骨干网络 Backbone、强特征提取网络 Neck 以及预测网络 Prediction 这 4 个部分构成。输入端采用 Mosaic 数据增强方法的同时, 融合了 Mixup 数据增强方法, 通过随机缩放、随机裁剪、随机排布、不同图片加权融合等方式对图片进行拼接, 丰富了数据的多样性, 可提升小目标的检测效果。

$$bbox_n = yolo(i) n = 0, 1, \dots, N \quad (1)$$

$$i_b = crop(i, bbox_n, ratio) \quad (2)$$

其中: $yolo$ 为螺栓目标检测模型, $bbox_n$ 为识别到的螺栓框其形状为 $N \times 4$, N 为识别到的螺栓数量, 4 为 $[x_1, y_1, x_2, y_2]$ 表示识别螺栓框的坐标, x_1, y_1 为原始图像 i 的左上角坐标, x_2, y_2 为原始图像 i 的右下角坐标, $crop$ 为从图像 i 裁剪螺栓方法, $ratio$ 为在 1 到 1.1 之间随机取值的螺栓图像坐标放大比率。 i_b 为无标签的螺栓数据集。

2.1.2 螺栓状态分类数据集

螺栓状态分类数据集用于预训练模型的迁移学习和有监督学习。螺栓的状态由开口销、单螺母和双螺母的状态组成, 状态有 3 种形式分别为存在、不存在、未知。通过人工识别对螺栓的状态进行标注。

2.1.3 螺栓图像检索数据集

通过对输电线路巡检的图像中的螺栓进行分析, 将螺栓按照不同位置 and 不同作用划分为 6 种螺栓类型。6 种螺栓分别为: 塔身垂直螺栓、塔身 U 型螺栓、活动件水平螺栓、活动件垂直螺栓, 地线挂点线夹螺栓、绝缘子下挂点线夹螺栓。每种类别的螺栓按照图片清晰度又分为清晰螺栓和模糊螺栓。

2.2 基于 DINO 的自监督模型

2.2.1 DINO 自监督框架

DINO 自监督学习框架是目前最先进的自监督学习框架, 本文首次将 DINO 自监督学习框架应用输电线路螺栓检测任务中。DINO^[31], 该方式的网络结构包含两个结构完全相同的网络结构, 一个作为学生网络一个作为教师网络。

知识蒸馏的学习方法通过训练学生网络 $g_s(\theta_s)$, 将训练结果匹配给教师网络 $g_t(\theta_t)$, 分别用 θ_s 和 θ_t 参数化。给定一个无标签的螺栓图像数据集 i_b 作为输入, 学生网络教师网络分别输出 K 维向量, 通过 softmax 函数进行归一化得到学生网络输出的概率向量和老师网络输出的概率向量, 分

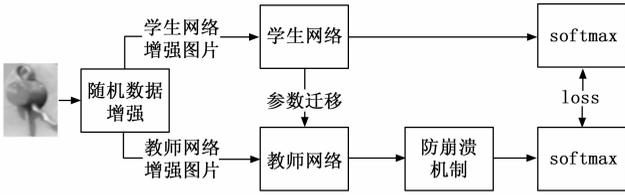


图 3 DINO 螺栓自监督框架结构图

别用 P_s 和 P_t 表示。

$$P_s(i)^{(n)} = \frac{\exp p(g\theta_s)(i)^{(n)} / \tau_s}{\sum_{k=1}^K \exp p(g\theta_s)(i)^{(k)} / \tau_s} \quad (3)$$

$$P_t(i)^{(n)} = \frac{\exp p(g\theta_t(i)^{(n)} / \tau_t)}{\sum_{k=1}^K \exp p(g\theta_t(i)^{(k)} / \tau_t)} \quad (4)$$

其中: τ_s 和 τ_t 分别为学生网络的温度参数和教师网络的温度参数。

损失函数为:

$$\text{loss} = -P_t(i) \log P_s(i) \quad (5)$$

通过模型不断学习, 得到使 loss 最小的 θ_s 作为螺栓自监督与训练模型参数。

2.2.2 ViT 主干网络

ViT^[32] 主干网络是 DINO 自监督框架中教师网络和学生网络常用的结构。该研究主要对比了不同规格的 ViT 和 ResNet50 的在螺栓螺母检测任务中的精度表现。ViT 将 Transformer 模型从自然语言处理 NLP 成功应用计算机视觉领域, 并取得非常优秀的性能。该网络参考文本处理方法, 将图片分割成非重叠连续 N 个图像块, 每个图像小块的分辨率为 $h \times w$ 。将每个图像块通过一个线性层映射成 N 个向量, 并和一个可学习的向量组成一个 $(N+1)D$ 的向量, 同时在向量中添加图像块位置信息后, 将向量序列输入到 Transformer 中进行计算输出图像编码。

2.3 迁移学习

迁移学习将 DINO 得到的螺栓预训练大模型后添加一个可学习的多层感知机 MLP 用来学习一个特定的螺栓分类任务。螺栓分类任务通过标注少量的螺栓分类数据集, 在螺栓预训练大模型的基础上训练。经过迁移学习后, 得到螺栓图像的特征向量 f_i 。

$$f_i = \text{MLP}(g\theta_s(i)), f_i \in R^N * M \quad (6)$$

其中: M 为分类任务的类别数量, f_i 经过 softmax 函数得到分类的概率 P_i 。

$$P_{i,m} = \frac{\exp p(f_i^{(m)})}{\sum_{m=1}^M \exp p(f_i^{(m)})} \quad (7)$$

损失函数采用 CE (Cross Entropy)^[34] 进行计算。具体而言, 每一类的预测标签与标注标签计算 CE 损失。

2.4 螺栓图像检索方法

图像特征向量的高效表示是图像检索的一个重要基础, 使用 DINO 得到的螺栓预训练大模型得到螺栓图像特征向量进行图像检索。采用 K 最近邻 (K-Nearest Neighbor, KNN) KNN^[33] 方法进行图像检索。将螺栓图像检索数据集中的图像经过螺栓预训练大模型得到螺栓图像的特征向量。K 最近邻检索通过在螺栓图像检索数据集中查找与查询螺栓特征向量距离最近的向量来获得相同类型的螺栓图像。螺栓图像特征向量之间的距离采用余弦相似度方法计算。

bor, KNN) KNN^[33] 方法进行图像检索。将螺栓图像检索数据集中的图像经过螺栓预训练大模型得到螺栓图像的特征向量。K 最近邻检索通过在螺栓图像检索数据集中查找与查询螺栓特征向量距离最近的向量来获得相同类型的螺栓图像。螺栓图像特征向量之间的距离采用余弦相似度方法计算。

3 实验结果与分析

本研究将自监督学习应用到输电线路螺栓检测任务中, 并验证自监督学习在输电线路螺栓检测任务中的效果。首先完成数据集的建立, 包括螺栓无监督学习数据集、迁移学习数据集、螺栓检索数据集。然后通过自监督学的视觉表征特征验证自监督学习在输电线路中螺栓特征的学习效果。最后使用自监督学的螺栓预训练大模型在螺栓分类任务和螺栓检索任务中进行对比实验。

3.1 数据集建立

3.1.1 自监督无标签数据集

为了从原始数据获得大量的自监督无标签的螺栓数据集, 使用少量标注数据进行有监督训练目标检测模型, 再使用模型对原始图像推理, 最后获得大量的无标注螺栓图像。人工标注 12 302 张原始图像中的螺栓, 使用 yolo 模型进行训练。batch size 设置为 240, 使用 CSPResNeXt50 主干网络在单机 8 个 A100 GPU 上进行训练。优化器使用 Adam。学习率采用 cosine 衰减策略。训练 100 个 epoch。训练环境配置及参数, 本实验使用 Python 3.7、PyTorch 1.7.1、CUDA 11.0、torchvision 0.8.1 环境进行有监督学习训练。



图 4 原始图像螺栓检测结果

对检测到的螺栓进行抠图, 获得 115 万输电线路单螺栓图像, 用于 DINO 框架下的自监督学习。在螺栓抠图的过程中, 将螺栓图像长和宽各放大 1.1 倍, 使螺栓位于图像中央。通过该方式获的数据数量多, 螺栓类型多样, 螺栓数据与真实数据一致。

3.1.2 螺栓状态有标签数据集

为了减少人工标注成本, 仅挑选出小部分螺栓图像进行人工标注, 将标注的图像用于有监督学习和迁移学习任务。第一行到第六行分别标注为单螺母存在、开口销存在、双螺母存在、单螺母未知、开口销未知、双螺母未知。

3.1.3 螺栓图像检索验证集

为了验证自监督螺栓预训练大模型在检索任务中的效果, 建立螺栓图像检索数据集。通过人工筛选了 6 类螺栓数据用于图像检索任务, 每类螺栓数据分为清晰和模糊两个

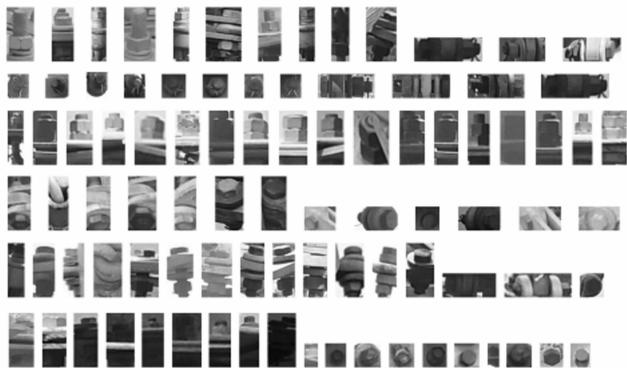


图 5 螺栓状态分类数据集

表 1 螺栓状态分类数据集标签分布

数据集	类别	训练集	验证集
单螺母存在状态	存在	5 925	658
	不存在	2 097	233
	未知	636	70
双螺母存在状态	存在	1 458	162
	不存在	5 961	662
	未知	627	69
开口销存在状态	存在	2 933	325
	不存在	3 932	436
	未知	1 205	133

类别。清晰和模糊的标准按照是否可以看清螺栓中每个部件的边缘轮廓进行区分。6 类螺栓为输电线路中常见的螺栓图像, 包括双螺母螺栓、单螺母螺栓、开口销螺栓, 其中双螺母螺栓包括塔身垂直螺栓、塔身 U 型螺栓, 单螺母螺栓包括地线挂点线夹螺栓、绝缘子下挂点线夹螺栓, 开口销螺栓包括活动件螺栓 (水平方向), 活动件螺栓 (竖直方向)。每个类别螺栓数据分布如表 2, 清晰螺栓每个类别为数量为 1 332 张 2 632 张图像, 模糊类别的螺栓数数量为 63 到 1 344 张图像。如图 6, 数据集中包含 6 个类别螺栓的查询图像 (左侧第一列) 和清晰图像 (中间部分) 与模糊图像 (右侧部分), 图中从上到下 6 列分别为地线挂点线夹螺栓、活动件螺栓 (竖直方向)、绝缘子下挂点线夹螺栓、塔身 U 型螺栓、活动件螺栓 (水平方向)、塔身垂直螺栓。通过每类螺栓的查询图像检索该类别螺栓图像。

表 2 螺栓图像检索数据集标签分布

螺栓类型	种类	清晰	模糊
双螺母螺栓	塔身垂直螺栓	2 342	1 036
	塔身 U 型螺栓	1 332	63
单螺母螺栓	地线挂点线夹螺栓	1 368	867
	绝缘子下挂点线夹螺栓	1 873	1 334
开口销螺栓	活动件螺栓(水平方向)	2 632	698
	活动件螺栓(竖直方向)	1 876	453



图 6 螺栓检索数据集

3.2 自注意力视觉表征

使用没有标签的螺栓数据集对模型进行预训练。batch size 设置为 1 024, 分别使用 resnet50 和 ViT-S/8 主干网络在单机 8 个 A100 GPU 上进行训练。优化器使用 Adamw。学习率在前 10 个 epochs 使用线性上升策略从 0 至 0.002。其中 0.002 使用 $Lr = 0.0005 * \text{batchsize}/256$ 计算方法获得, 在 10 个 epochs 后采用 cosine 衰减策略, 权重衰减采用从 0.04 到 0.4 的 cosine 衰减策略。学生网络的温度参数设置为 0.1, 教师网络的温度参数前 30 个 epochs 采用 0.04 到 0.07 的线性变化。训练环境配置及参数, 本实验使用 Python 3.6、PyTorch 1.7.1、CUDA 11.0、torchvision 0.8.2 环境进行系监督学习训练。

使用螺栓自监督预训练大模型, 对双螺母螺栓、水平视角螺栓、垂直视角螺栓图片进行推理获得螺栓图片注意力图。从注意力图中可以看出, 基于 DINO 的自监督螺栓预训练大模型可以学习到螺栓的特征。图 6 中上层结果为双螺母螺栓结果, 中间层结果为水平视角的螺栓、底层为竖直方向的螺栓。观察实验结果可知, 模型能很好的学习到两个螺母、螺栓杆、螺帽、连接件的特征。说明 DINO 对于螺栓自监督学习具有很好的效果。

3.3 自监督预训练迁移学习实验

为了验证自监督预训练的效果, 采用 5 种 backbone 进行自监督预训练实验。5 种 backbone 分别为 Resnet50^[36]、ViT-S/16、ViT-S/8、ViT-B/16、ViT-B/8。迁移学习任务分别为开口销状态分类、单螺母状态分类、双螺母状态分类。在表中比较了 5 中主干网络在自监督预训练迁移学习和有监督学习条件下开口销状态、单螺母状态、双螺母状态的准确率。准确率使用 acc 表示, 单位 %。

$$acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (8)$$

其中: TP、TV、FP、FN 分别为正例预测正确的数量、负例预测错误的数量、负例预测正确的数量、正例预测错误的数量。

可以看出基于 Dino 的自监督螺栓预训练大模型的迁移

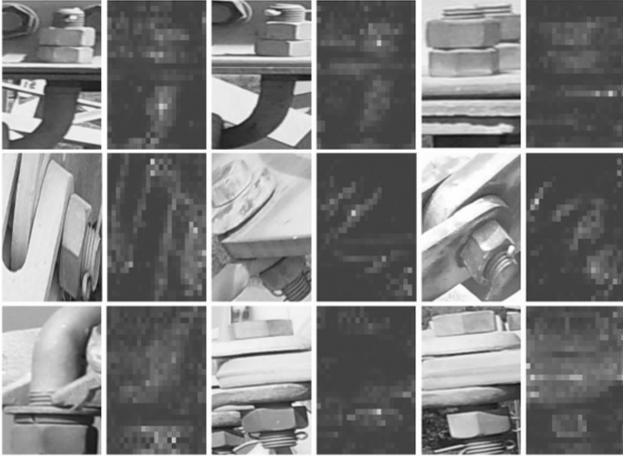


图 7 螺栓自监督学习注意力图

学习在螺栓状态分类任务中表现优于有监督学习。螺栓预训练大模型在在分类任务中相对于监督学习准确率提升了 2% 到 7%，在 ViT-B/8 的主干网络上的自监督预训练迁移学习表现最好。

表 3 不同 backbone 和不同迁移学习任务的 acc 结果

模型	学习方式	开口销状态分类/%	单螺母状态分类/%	双螺母状态分类/%
Resnet50	监督学习	75.5	72.4	73.8
	自监督预训练	78.2	77.4	79.1
ViT-S/16	监督学习	66.4	67.3	64.6
	自监督预训练	69.9	68.4	70.2
ViT-S/8	监督学习	76.3	79.4	78.3
	自监督预训练	80.3	81.3	83.5
ViT-B/16	监督学习	70.6	69.3	68.7
	自监督预训练	74.3	75.1	72.3
ViT-B/8	监督学习	79.5	78.2	77.3
	自监督预训练	86.3	85.2	81.5

3.4 螺栓图像检索

将 DINO 自监督预训练模型应用到螺栓图像检索任务中，将 DINO 自监督预训练模型参数冻结，并提取训练数据集的螺栓图像特征。使用 KNN 方法验证 DINO 自监督预训练模型获得的螺栓图像特征的在检索任务中的效果。

为了评估性能，使用平均精度 (AP) 度量作为查询的精度-召回曲线下的面积计算。精度定义为检索到的正图像与检索到的总图像数量之比。召回率定义为检索到的正例图像数量与数据集中正例图像总数的比值。理想的精度-召回曲线在所有召回级别上的精度为 100%，这对应于平均精度为 100%。计算 6 类螺栓的每类 AP 分数，将它们平均起来以获得 (mAP) 分数来评估整体表现。

在自建的螺栓数据集上的检索结果如表 4，通过实验结果可知 DINO 的 mAP 在 ResNet50 和 ViT-S/8 主干网络上均比有监督学习高，清晰图像检索任务比模糊的效果要好。DINO 自监督预训练模型在螺栓图像检索任务效果较好，平

均精度提升了 8%。

表 4 螺栓自监督大模型检索任务结果

方法	Backbone	螺栓图像检索数据集	
		清晰/%	模糊/%
有监督	Resnet50	28.5	11.5
DINO	ViT-S/8	33.2	15.3
	Resnet50	36.3	19.8
	ViT-S/8	43.2	23.4

4 结束语

本文提出了一种基于自监督学习的输电线路螺栓检测技术，首次将 DINO 自监督学习应用到输电线路螺栓检测任务中。从原始输电线路数据中生成无标签螺栓数据集、螺栓状态分类数据集、螺栓图像检索验证集。分别在 3 个数据集上完成自监督训练、有监督螺栓分类迁移学习和螺栓图像检索任务实验。实验结果表明，自监督螺栓预训练大模型可以学习到螺栓的组成特征，并且可以提升下游的分类任务准确率，在螺栓检索任务效果也有明显提升。无标签的螺栓数据集获取成本相对较低，可以获得更多的螺栓数据集，通过自监督的学习方式训练一个关于螺栓检测任务更通用的螺栓预训练大模型，为输电线路的螺栓缺陷检测提供更实用的模型基础。

参考文献:

- [1] TEIMOURZADEH H, MOHAMMADI-LVATLOO B, SHAHIDEPOUR M. Adaptive protection of partially coupled transmission lines [J]. IEEE Transactions on Power Delivery, 2020, 36 (1): 429 - 440.
- [2] CHAWEZ J J, POPOV M, LÓPEZ D, et al. S-Transform based fault detection algorithm for enhancing distance protection performance [J]. International Journal of Electrical Power & Energy Systems, 2021, 130: 106966.
- [3] GUILLEN D, PATERNINA M R A, ZAMORAA, et al. Detection and classification of faults in transmission lines using the maximum wavelet singular value and Euclidean norm [J]. IET Generation, Transmission & Distribution, 2015, 9 (15): 2294 - 2302.
- [4] GODSE R, BHAT S. Mathematical morphology-based feature-extraction technique for detection and classification of faults on power transmission line [J]. IEEE Access, 2020, 8: 38459 - 38471.
- [5] ALHASSANA B, ZHANG X, SHENH, et al. Power transmission line inspection robots: A review, trends and challenges for future research [J]. International Journal of Electrical Power & Energy Systems, 2020, 118: 105862.
- [6] ZHAO Z, QI H, QI Y, et al. Detection method based on automatic visual shape clustering for pin-missing defect in transmission lines [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69 (9): 6080 - 6091.

- [7] HAN Y, HAN J, NI Z, et al. Instance Segmentation of Transmission Line Images Based on an Improved D-SOLO Network [C] //2021 IEEE 3rd International Conference on Power Data Science (ICPDS). IEEE, 2021: 40-46.
- [8] HE T, ZENG Y, HU Z. Research of multi-rotor UAVs detailed autonomous inspection technology of transmission lines based on route planning [J]. IEEE Access, 2019, 7: 114955-114965.
- [9] WANG C, WANG N, HO S C, et al. Design of a new vision-based method for the bolts looseness detection in flange connections [J]. IEEE Transactions on Industrial Electronics, 2019, 67 (2): 1366-1375.
- [10] LI Y, LI Z, LIU Y, et al. Pin bolt state identification using cascaded object detection networks [J]. Frontiers in Energy Research, 2022, 10: 813945.
- [11] XIAO L, WU B, HU Y. Missing small fastener detection using deep learning [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 70: 1-9.
- [12] WANG K, WANG J, LIU G, et al. RetinaNet algorithm based on auxiliary data for intelligent identification on pin defects [J]. Guangdong Electric Power, 2019, 32 (9): 41-48.
- [13] ZHAO Z, QI H, QI Y, et al. Detection method based on automatic visual shape clustering for pin-missing defect in transmission lines [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69 (9): 6080-6091.
- [14] SHI J, LI Z, GU C, et al. Research on foreign matter monitoring of power grid with faster R-CNN based on sample expansion [J]. Power System Technology, 2020, 44 (1): 44-51.
- [15] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single shot multibox detector [C] //Computer Vision - ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, Proceedings, Part I 14. Springer International Publishing, 2016: 21-37.
- [16] ZHAO L, LI S. Object detection algorithm based on improved YOLOv3 [J]. Electronics, 2020, 9 (3): 537.
- [17] FU J, SHAO G, WU L, et al. Defect detection of line facility using hierarchical model with learning algorithm [J]. High Voltage Eng, 2017, 43 (1): 266-275.
- [18] KHAN K, REHMAN S U, AZIZ K, et al. DBSCAN: Past, present and future [C] //The fifth international conference on the applications of digital information and web technologies (ICADIWT 2014). IEEE, 2014: 232-238.
- [19] CHENZ, WANG L, FEI Z, et al. Weakly Supervised Bolt Detection Model Based on Attention Mechanism [C] //Digital TV and Wireless Multimedia Communications; 18th International Forum, IFTC 2021, Shanghai, China, December 3 - 4, 2021, Revised Selected Papers. Singapore: Springer Singapore, 2022: 325-337.
- [20] KONG Y, LIU X, ZHAO Z, et al. Bolt defect classification algorithm based on knowledge graph and feature fusion [J]. Energy Reports, 2022, 8: 856-863.
- [21] CHENT, KORNBLITH S, NOROUZI M, et al. A simple framework for contrastive learning of visual representations [C] //International conference on machine learning. PMLR, 2020: 1597-1607.
- [22] HE K, FAN H, WU Y, et al. Momentum contrast for unsupervised visual representation learning [C] //Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2020: 9729-9738.
- [23] XINLEI C, SAINING X, KAIMING H. An empirical study of training self-supervised visual transformers [J]. arXiv preprint arXiv: 2104. 02057, 2021, 8.
- [24] CHENX, FAN H, GIRSHICK R, et al. Improved baselines with momentum contrastive learning [J]. arXiv preprint arXiv: 2003. 04297, 2020.
- [25] GRILL J B, STRUB F, ALTCHÉ F, et al. Bootstrap your own latent-a new approach to self-supervised learning [J]. Advances in neural information processing systems, 2020, 33: 21271-21284.
- [26] CARON M, TOUVRON H, MISRA I, et al. Emerging properties in self-supervised vision transformers [C] //Proceedings of the IEEE/CVF international conference on computer vision. 2021: 9650-9660.
- [27] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. Advances in neural information processing systems, 2017, 30.
- [28] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: Optimal speed and accuracy of object detection [J]. arXiv preprint arXiv: 2004. 10934, 2020.
- [29] REDMON J, FARHADI A. Yolov3: An incremental improvement [J]. arXiv preprint arXiv: 1804. 02767, 2018.
- [30] REDMON J, FARHADI A. YOLOv4: better, faster, stronger [C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 7263-7271.
- [31] HINTON G, VINYALS O, DEAN J. Distilling the knowledge in a neural network [J]. arXiv Preprint arXiv: 1503. 02531, 2015.
- [32] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16x16 words: Transformers for image recognition at scale [J]. arXiv preprint arXiv: 2010.11929, 2020.
- [33] WU Z, XIONG Y, YU S X, et al. Unsupervised feature learning via non-parametric instance discrimination [C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 3733-3742.
- [34] DE BOER P T, KROESE D P, Mannor S, et al. A tutorial on the cross-entropy method [J]. Annals of Operations Research, 2005, 134: 19-67.
- [35] DANIELSSON P E. Euclidean distance mapping [J]. Computer Graphics and image processing, 1980, 14 (3): 227-248.