

基于孪生网络的自监督太阳能电池板裂纹检测方法^{*}

崔康 陈平

(中北大学信息探测与处理山西省重点实验室 太原 030051)

摘要:太阳能电池板的裂纹缺陷检测能够避免电能转换效率低,以及短路造成起火的损失。针对现存对比学习方法中存在细微裂纹漏检导致检测精度低,并且严重依赖构建负样本等问题,提出了一种基于孪生网络的两阶段自监督裂纹检测方法。第1阶段提出了一种基于卷积神经网络(convolutional neural network,CNN)和Transformer的预训练编码器模型,通过孪生网络架构学习样本的精细特征表示,提高对电池板细微裂纹的特征表示能力;第2阶段基于预训练模型在少量标注样本下学习分类器以区分缺陷样本。为进一步区分不影响电池板功能的纵向裂纹,另增加了一个分类头进行判别。在ELPV数据集上的实验结果表明,方法在测试准确度方面优于其他相关检测方法,在只对数据进行少量标注的情况下准确度达到83.26%,单张检测时间为6.1 ms,同时在裂纹图像中检出纵向裂纹的召回率也有76.7%。

关键词:太阳能电池板;裂纹检测;对比学习;孪生网络

中图分类号: TM914 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Crack detection method for solar panels based on siamese network and self-supervised learning

Cui Kang Chen Ping

(Shanxi Province Key Laboratory of Information Detection and Processing, North University of China, Taiyuan 030051, China)

Abstract: Crack defect detection in solar panels can prevent energy conversion inefficiency and the risk of short circuits causing fires. In this paper, we propose a two-stage self-supervised crack detection method based on a siamese network to address the limitations of existing contrastive learning methods, such as slight crack omission leading to low detection accuracy and heavy reliance on constructing negative samples. In the first stage, a pre-trained encoder model based on CNN and Transformers is proposed to learn fine-grained feature representations of samples using the siamese network architecture, thereby improving the feature representation capability for micro-cracks in solar panels. In the second stage, a classifier is learned based on the pre-trained model with a small amount of annotated samples to distinguish defect samples. Additionally, a separate classification head is added to further differentiate longitudinally oriented cracks that do not affect the functionality of the solar panels. Experimental results on the ELPV dataset demonstrate that the proposed method outperforms other related detection methods in terms of test accuracy, achieving an accuracy of 83.26% with only a small amount of annotated data, the detection time of single sheet was 6.1 ms, and a recall rate of 76.7% for detecting longitudinally oriented cracks in crack images.

Keywords: solar panels; crack detection; contrast learning; siamese network

0 引言

近年来,社会工业发展所带来的环境恶化和能源危机等问题日趋严重,而太阳能作为一种清洁、安全和丰富的

可再生能源广受人们关注^[1]。太阳能电池板作为光伏发电的最主要器件,在制造、运输或使用过程中,由于压力不均或操作不当,可能会在太阳能电池表面产生裂纹。光伏组件的转换效率受到太阳能电池表面裂纹的严重影响,由

收稿日期:2023-08-26

^{*} 基金项目:国家自然科学基金(61871351)项目资助

此产生相应程度的电力损失^[2]甚至会有短路或是起火的风险,因此针对太阳能电池板裂纹检测的研究具有重要意义。

随着计算机视觉技术的发展,使用机器视觉的方法进行无损检测,避免了传统人工检测效率低、耗时长、成本高、劳动强度大、人眼的分辨率有限并带有主观意识的问题^[3]。针对裂纹检测任务,传统图像处理方式中,Anwar等^[4]基于图像梯度特征,利用二值化和形态学后处理的方法对太阳能电池板进行裂纹检测,此外还包括阈值分割^[5]、边缘检测^[6]等方法很难做到对裂纹特征完整的建模和迁移,泛化性差且效果不佳。尽管基于特征聚类^[7]和支持向量机^[8]等机器学习方法在裂纹检测的任务中取得了较大的进步,但这些方法仍然存在一定的局限性,检测精度受多种因素影响,如缺陷位置和尺寸。

近年来,随着卷积神经网络(convolutional neural networks, CNN)在诸多计算机视觉领域成功应用,基于深度学习的缺陷检测方法也得到快速发展^[9],根据任务与网络结构不同大致划分为分类、检测与分割3种方法。其中目标检测方面包括基于YOLO为代表的单阶段缺陷检测方法^[10-11],和以Faster R-CNN为代表的两阶段算法^[12],此类方法需要对裂纹位置进行精准定位来判断是否存在裂纹,而裂纹定位难度较大,并且还需对图像数据进行像素级标注;同时利用Mask R-CNN对裂纹缺陷直接进行分割的方法^[13]尽管在缺陷信息获取上有其优势,但与检测网络一样,需要大量的标注数据,而且其标注信息是逐像素,因此需花费更多的标注精力和成本,同时检测过程复杂、速度较慢。

而基于图像分类的检测方法只需对采集的图像进行有裂纹的判别,即可实现对电池板的裂纹检测。检测网络大都使用VGG、ResNet用于特征提取和分类,姜瑾等^[14]对太阳能电池板图像进行类别标记,得到数据集后基于VGG16完成模型训练,利用模型对有无裂纹进行检测。此类有监督学习的方法都需要在大规模标注的数据集上进行训练,但是随着智能化的发展,如何减少对标注信息的依赖是裂纹检测方法在实际应用中需要解决的一个关键问题。

自监督学习很大程度上减少了标注成本,大体分为生成式学习和对比式学习,生成式学习通过对输入进行重构使输入和输出尽可能相似,其中凌旭峰等^[15]使用双通道生成式自监督学习方法,训练基于自注意力的缺陷识别网络,识别出太阳能电池板的裂纹缺陷;对比学习属于判别式自监督学习,其方法的核心思想是通过比较样本之间的相似性来学习样本的特征表示,不需要关注样本上繁琐的细节,而是专注在抽象语义级别的特征空间上学习对数据进行区分,可以帮助模型更好地理解数据的结构和语义信息从而提高模型的性能,同时模型优化简单、泛化性强,更适用于实际检测任务。其中Wang等^[16]利用对比学习框架SimCLR学习没有标签的输入图片获取图像

后基于预训练模型训练分类器实现对电池板有无裂纹的区分,但是此架构需要较大的批量来构建足够的负样本来避免模型坍塌,并且模型学习效果很大程度上受负样本数量的影响。此外,基于对比学习的裂纹检测方法因其特征提取不充分存在对细微裂纹漏检、检测精度不高等问题。

另外,电池片产生的电流主要依靠表面的主栅线及垂直于主栅线的细栅线搜集和导出。当隐裂导致细栅线断裂时,细栅线无法将收集的电流输送到主栅线,将会导致电池片部分甚至全部失效,还可能造成碎片、热斑等,同时引起组件的功率衰减。而垂直于主栅线的纵向裂纹几乎不影响细栅线,造成电池片失效的面积几乎为0。

因此,针对太阳能电池板裂纹检测任务中目前基于自监督对比学习的分类检测方法存在细微裂纹漏检,从而导致检测精度低并且严重依赖负样本等问题,从提高特征提取能力角度出发,本文提出了一种基于CNN和Transformer的预训练编码器模型来充分获取局部和全局信息,采用孪生网络架构^[17]进行表征学习,能够在不依赖负样本的情况下提高对特征的表示能力,获取更全面、更细微的特征表示;其次基于预训练网络训练线性分类器来实现对裂纹的检测。并且从实际的检测维护需求出发,在识别裂纹的基础上增加了一个分类器以区分不影响电池板功能的纵向裂纹。

1 本文方法

1.1 孪生网络架构

为了避免负样本缺失导致模型坍塌,且能学到很好的特征表示,选取孪生网络结合对比学习方法的网络架构进行预训练,该网络通过最大化同一图像的不同增广图像的相似性,使其避免崩溃解问题,在无需构建负样本对的情形下,通过小批处理训练也可以学习有意义的特征表达,并在下游任务上取得很好的效果。

网络总体架构如图1(a)所示,对于训练集中随机输入的图像 X ,使用随机数据增强生成两个图像 X_1 、 X_2 ,经过特征提取网络得到两个特征向量 f_1 、 f_2 ,然后将特征向量传递到投影头产生两个投影向量 Z_1 、 Z_2 ;将其中一个投影向量 Z_1 传递到预测头生成一个预测向量 P_1 ,最后通过最小化预测向量与另一个投影向量之间的距离,学会对同一图像的不同视图产生相似的特征表示。

1.2 预训练编码器

本文将CNN与Transformer相结合作为提取特征的编码器,以多层次的Transformer为基础,在网络的层与层之间插入传统卷积进行细粒度特征提取,通过卷积加全局注意力的方式层次化提取图像局部和全局特征。根据图1(b)所示,在第1部分首先对于输入图像先经过一个 3×3 卷积,步长为2,输出通道为32,以减小输入图像的大小,然后对其进行两次步长为1的 3×3 卷积来获得更好的局部信息。

接着第2部分由4个阶段组成,对于给定输入图像,

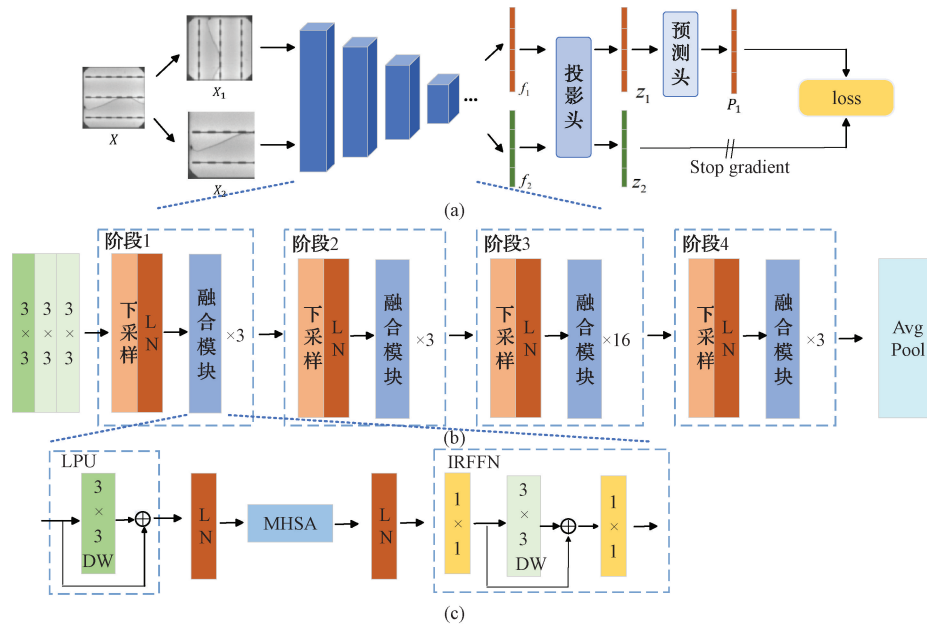


图1 (a)孪生网络总体架构;(b)编码器结构;(c)融合模块结构

可以获得4个不同分辨率的分层特征图,获得输入图像的多尺度表示,并且可以很容易地应用于下游任务。每个阶段的开始部分都使用了一个由卷积核 2×2 、步长为2的卷积层和归一化层组成的补丁嵌入层,作用是通过下采样将中间特征减小为 $1/2$ 大小,并将其投影到更大维度。4个阶段分别在补丁层后按顺序堆叠了数目为3、3、16、3个的CNN和Transformer融合模块,根据图1(c)所示,每个融合模块都是由局部感知单元(local perception unit, LPU)、多头自注意力(multi-head self-attention, MHSA)和反向残差前馈网络(inverted residual feed-forward network, IRFFN)组成。

其中,局部感知单元通过将输入图像信息,与 3×3 的DW深度卷积操作后相加,旨在增加空间信息、提取局部信息,用公式表示为:

$$LPU(X) = DWConv(X) + X \quad (1)$$

反向残差前馈网络功能类似于反向残差块,通过改变快捷连接的位置提高梯度的跨层传播能力,以获得更好的性能。由一个 1×1 的扩展层增加维度、一个 3×3 的深度卷积层对每个通道上的进行单独卷积提取局部信息,和一个投影层组成,根据结构表示为:

$$IRFFN(X) = Conv(F(Conv(X))) \quad (2)$$

其中:

$$F(X) = DWConv(X) + X \quad (3)$$

1.3 损失函数

在预训练部分,SimSiam框架中利用负余弦相似度计算两个向量的距离:

$$D(P_1, Z_2) = -\frac{P_1}{\|P_1\|^2} \cdot \frac{Z_2}{\|Z_2\|^2} \quad (4)$$

接着引入对称性构成损失函数,在相同的操作下应用于两个增强视图来优化模型,可以表示为:

$$L = \frac{1}{2}D(P_1, Z_2) + \frac{1}{2}D(P_2, Z_1) \quad (5)$$

最后根据防止模型坍塌的stop-gradient操作对上述公式进行简单的修改得到最终的损失函数:

$$L = \frac{1}{2}D(P_1, stopgrad(Z_2)) + \frac{1}{2}D(P_2, stopgrad(Z_1)) \quad (6)$$

1.4 训练线性分类器

在获取适用于下游任务的预训练模型后,冻结特征提取网络的卷积层,利用少量带有类别标签的数据在全连接层部分对其进行微调,提高线性分类器对数据的分类性能。先计算每个样本的预测概率分布 \tilde{y}_i 和真实标签的 y_i 之间的交叉熵损失:

$$L(\tilde{y}_i, y_i) = -\sum_j y_{i,j} \cdot \log(\tilde{y}_{i,j}) \quad (7)$$

式中: j 表示类别的索引, $y_{i,j}$ 是一个指示函数,如果样本 i 的真实标签是类别 j ,则为1,否则为0; $\tilde{y}_{i,j}$ 是样本 i 属于类别 j 的预测概率。

接着通过对整个训练数据集中每个样本的损失进行平均计算得到分类器的经验风险,分类器 f 的经验风险定义为:

$$f = (1/N) \cdot \sum_{i=1}^N L(\tilde{y}_i, y_i) \quad (8)$$

通过调整模型的权重和偏置等参数来最小化经验风险,来提高线性分类器在电池板数据上的分类性能。

基于优化完成的预训练模型和线性分类器,先对未知

且无标签的电池板数据进行有无裂纹的划分,然后将有裂纹部分中不影响电池板性能的纵向裂纹区分出来,则剩余的包含其他裂纹的电池片就是需要维修或更换的。

2 实验过程与结果

为了验证所提出方法的有效性,本文在 ELPV 数据集^[18-19]上对该方法的检测效果进行验证。数据集包含 2 624 个从 44 个不同的太阳能组件中提取的不同退化程度的功能和缺陷太阳能电池灰度图像样本,所有图像都在大小和视角方面进行了标准化,如图 2 所示。实验时对数据集进行了旋转、亮度变化、对比度变化方式将其扩充为 10 496 张图像。实验平台所用计算机配置为 RTX-3090 的 GPU,使用 Python3.6 和 Pytorch 工具箱进行实验。




图 2 太阳能电池板图像

2.1 预训练

在预训练阶段,使用了 ELPV 数据集中随机 9 000 张图像作为训练集,其中单晶裂纹、单晶无裂纹、多晶裂纹和多晶无裂纹各占一定比例。在实验中将图像大小设置为 224×224 ,对输入图像采用了随机裁剪、随机水平翻转、随机灰度、色彩抖动和高斯模糊 5 种数据增强方式。将数据集批处理大小设置为 128 放入网络进行预训练操作,通过损失值判断模型学习效果,学习率的大小设置为 0.000 3,如图 3 所示,损失值在 300 个 epoch 之后趋于平缓达到 -0.8。




图 3 训练损失曲线

1) 测试方法与指标

本文对模型训练 500 个 epoch 后采用 KNN 算法测试其效果,通过计算测试样本的特征与训练样本特征之间的欧氏距离,再根据与此测试样本距离最近的 10 个训练样本的标签所占比例得到分类类别,与真实标签比对得到测试结果。在此项任务中,将剩余的样本大致根据 2 : 1 的比例划分成训练集和测试集,其中将有裂纹的数据标记为 1,无裂纹的数据标记为 0。其中测试标准准确度 (accuracy) 的定义如下:

$$accuracy = \frac{TP + TN}{P + N} \quad (9)$$

式中: P 和 N 分别代表测试集中有裂纹和无裂纹的数量; TP 和 TN 则分别表示将有裂纹和无裂纹的样本预测结果正确的数量。

2) 实验对比模型

为了验证本文所提出的基于 CNN 和 Transformer 的预训练编码器模型,相较于 SimCLR 架构使用的 ResNet-50 在电池板图像特征提取方面的优越性,和所采用的孪生网络结合对比学习的架构进行预训练在小批处理次下有较好效果,设计了一系列对比实验,结果如表 1 所示。由表 1 可以看出,针对包含不同尺寸裂纹的太阳能电池板裂纹检测任务,本文所采用的架构在较小批处理次情况下仍使网络有较强的学习能力,还有所提出的编码器结构都对检测精度上有所提高。

表 1 不同架构在 KNN 算法的准确度实验结果

架构	准确度/%
SimCLR(ResNet-50)	70.53
SimCLR(本文编码器)	73.08
本文架构(ResNet-50)	71.87
本文架构与编码器	75.44

2.2 线性分类

将训练集放入网络架构经过 500 个 epoch 得到预训练模型,用所标注的 1 000 张带有 0 和 1 类别标签的样本基于特征提取层训练线性分类器,在经过 800 个 epoch 之后对 496 张测试集进行分类结果测试,根据准确度的定义计算准确度为 83.26%,经过训练分类器后对电池板裂纹检测的准确度提升了 7.82%。

1) 对比实验

将本文方法与生成式自监督学习方法、基于 ResNet-50 和交叉熵损失的训练分类器方法和基于 SimCLR 的对比学习检测方法在检测准确度和检测速度方面进行比较。表 2 为几种方法在相同实验条件下对 496 张测试图测得的准确度,以及对单张图像检测时间。

2) 区别纵向裂纹

接着对 400 张含裂纹的样本进行类别标注,包含平行于主栅线裂纹、垂直于栅线裂纹、斜裂纹以及综合型裂纹

表2 3种方法准确度与检测速度的比较

方法	类型	准确度/%	单张检测时间/ms
生成式自监督方法 ^[15]	生成式自监督	81.74	13.6
ResNet-50+Cross-Entropy	有监督	80.91	4.2
SimCLR+Cross-Entropy	对比式自监督	76.21	6.5
本文方法	对比式自监督	83.26	6.1

4种类型,基于所得预训练模型再进行相同操作的线性分类器训练。用包含146张垂直于栅线裂纹的若干样本测试,将其中112张纵向裂纹样本区分出来,召回率为76.7%。

2.3 实验结果分析

由表1可知,本文提出的编码器与网络架构相比于ResNet-50与SimCLR架构在准确度方面有较为明显的提升,验证了两者在检测任务中特征提取能力方面都有所增强。由表2可知,本文方法相比于有监督在避免了大规模的数据标注基础上检测精度更高,这是由于太阳能电池板的缺陷是开放式的,没有固定模式,在不对缺陷区域进行定位的情况下,传统有监督学习方法难以准确提取特征,也就难以实现准确识别。相比于生成式自监督,本文采用的对比式属于判别式检测方法,检测速度比生成式自监督方法更快,并且具有模型优化简单和泛化性更强等特点,同时利用所提出的编码器和网络架构很大程度上解决了现有对比式自监督方法存在检测精度低的问题,使其更适用于智能、快捷、高效的工业缺陷检测。

3 结论

本文提出了一种基于简单孪生网络的两阶段裂纹检测方法,提出了一种基于CNN和Transformer的预训练编码器模型,通过孪生网络架构学习样本的精细特征表示;然后基于预训练模型在少量标注样本下学习分类器实现对裂纹的检测。在相同的参数设置下,本文算法在ELPV数据集上的测试表现优于其他相关检测方法,在只对数据进行少量标注的情况下准确度达到83.26%,验证了所提方法的有效性。同时为了节约维修成本,在裂纹图像中检出不影响电池板功能的纵向裂纹的召回率也有76.7%。

尽管本文方法在太阳能电池裂纹的检测中显示出了积极的效果,但仍需要做大量的工作来提高准确性。在后续研究中,会考虑对检测部分进行优化,还有对纵向裂纹进行更精准的数据上的定义。

参考文献

[1] DOLARA A, LAZAROIU G C, LEVA S, et al. Snail trails and cell microcrack impact on PV module

maximum power and energy production[J]. IEEE Journal of Photovoltaics, 2016, 6(5): 1269-1277.

[2] QIAN X, ZHANG H, YANG C, et al. Micro-cracks detection of multicrystalline solar cell surface based on self-learning features and low-rank matrix recovery[J]. Sensor Review, 2018, 38(3): 360-368.

[3] 赵明月, 吴一全. 基于机器视觉的表面缺陷检测方法研究进展[J]. 仪器仪表学报, 2022, 43(1): 198-219.

[4] ANWAR S A, ABDULLAH M Z. Micro-crack detection of multicrystalline solar cells featuring an improved anisotropic diffusion filter and image segmentation technique[J]. EURASIP Journal on Image and Video Processing, 2014, DOI: 10.1186/1687-5281-2014-15.

[5] 张翰进, 傅志中, 念蓓, 等. 双峰法与Otsu法结合在太阳能电池缺陷检测中的应用[J]. 计算机系统应用, 2012, 21(1): 115-117, 131.

[6] 都胡平, 刘光宇, 薛安克. 基于机器视觉的光伏电池位置检测方法[J]. 工业控制计算机, 2019, 32(9): 19-20.

[7] YANG H, CHEN Y, SONG K, et al. Multiscale feature clustering-based fully convolutional autoencoder for fast accurate visual inspection of texture surface defects[J]. IEEE Transactions on Automation Science and Engineering, 2019, 16(3): 1450-1467.

[8] DEMANT M, WELSCHEHOLD T, OSWALD M, et al. Microcracks in silicon wafers I: Inline detection and implications of crack morphology on wafer strength[J]. IEEE Journal of Photovoltaics, 2015, 6(1): 126-135.

[9] 陶显, 侯伟, 徐德. 基于深度学习的表面缺陷检测方法综述. 自动化学报, 2021, 47(5): 1017-1034.

[10] 谢林森, 朱文忠, 谢康康, 等. 基于改进YOLOv5s的光伏电池EL缺陷图像检测模型[J]. 国外电子测量技术, 2023, 42(6): 93-102.

[11] 范先友, 过峰, 俞建峰, 等. 基于改进YOLOv7的液晶面板电极缺陷视觉检测技术研究[J]. 电子测量与仪器学报, 2023, 37(9): 225-233.

[12] 伊欣同, 单亚峰. 基于改进Faster R-CNN的光伏电池内部缺陷检测[J]. 电子测量技术, 2021, 44(1): 40-47.

[13] ATTARD L, DEBONO C J, VALENTINO G, et al. Automatic crack detection using mask R-CNN[C]. 2019 11th International Symposium on Image and Signal Processing and Analysis (ISPA). IEEE, 2019: 152-157.

[14] 姜瑾, 李明, 朱美强, 等. 基于卷积神经网络的室外运行太阳能电池板裂纹检测[J]. 扬州大学学报(自然科学版), 2020, 23(1): 49-53.

[15] 凌旭峰, 周丽婕, 祝毓, 等. 基于生成式自监督学习的

- 太阳能电池板缺陷检测[J]. 机械制造, 2022, 60(7): 12-18.
- [16] WANG Y, SHAN S, ZHANG N, et al. Contrastive learning for solar cell micro-crack detection[C]. 6th International Workshop on Pattern Recognition, 2021: 99-105.
- [17] CHEN X, HE K. Exploring simple siamese representation learning[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 15750-15758.
- [18] DEITSCH S, BUERHOP-LUTZ C, SOVETKIN E, et al. Segmentation of photovoltaic module cells in electroluminescence images[J]. Machine Vision and Applications, 2021, DOI:10.1007/s00138-021-01191-9.
- [19] DEITSCH S, CHRISTLEIN V, BERGER S, et al. Automatic classification of defective photovoltaic module cells in electroluminescence images[J]. Solar Energy, 2019, 185: 455-468.

作者简介

崔康, 硕士研究生, 主要研究方向为自监督深度学习。

E-mail: 2223435378@qq.com

陈平, 博士, 教授, 主要研究方向为信号与信息处理、图像处理与重建、光电检测等。

E-mail: pc0912@163.com