

# 基于双通道多尺度注意力机制的 光伏板裂缝检测方法

强浩<sup>1,2</sup>, 叶波<sup>1</sup>, 唐文祺<sup>1</sup>

(1. 常州大学 机械与轨道交通学院, 智能制造产业学院, 江苏 常州 213164;  
2. 江苏省能源动力高端装备工程研究中心, 江苏 常州 213164)

**摘要:** 针对目前传统边缘检测方法提取出的图像边缘轮廓模糊、不连续等问题, 提出一种基于双通道多尺度注意力机制的光伏板裂缝检测方法, 实现对图像低级边缘、边界、目标轮廓的检测; 首先构建了双通道主干网络, 包含语义分支通道和空间细节分支通道; 其次, 基于多尺度原则构建了多尺度及注意力机制模块, 对特征图像的高、宽、通道的维度变换, 分配特征权重, 在捕捉跨通道信息的同时, 还能够捕捉方向感知和位置感知的信息; 最后将空洞融合模块融合到语义分支通道中, 提升网络提取特征信息的能力。实验结果表明, 所提出的算法对光伏板图像边缘检测性能有提升, 相较 HED、RCF 与 FCN 算法,  $F_1$  值提升了 2.83%、0.37% 与 1.54%, 获得了较为清晰的裂缝图像。

**关键词:** 裂缝检测; 多尺度; 注意力机制; 双通道网络; 空洞融合

## Photovoltaic Panel Crack Detection Method Based on Dual-Channel Multi-Scale Attention Mechanism

QIANG Hao<sup>1,2</sup>, YE Bo<sup>1</sup>, TANG Wenqi<sup>1</sup>

(1. Intelligent Manufacturing Branch, School of Mechanical Rail Transit, Changzhou University,  
Changzhou 213164, China;  
2. Energy and Power Advanced Equipment Engineering Research Center, Changzhou 213164, China)

**Abstract:** Aiming at the problems of fuzzy and discontinuous image edge contours extracted by traditional edge detection methods, a photovoltaic panel crack detection method based on dual-channel multi-scale attention mechanism is proposed to detect the detections of low-level edges, boundaries, and target contours. Firstly, the dual-channel backbone network was constructed, including the semantic branch channel and spatial detail branch channel. Secondly, based on the multi-scale principle, the multi-scale and attention mechanism was built to transform the dimensions of the height, width, and channel for the feature image, allocate the feature weights, capture the cross-channel information, and capture the direction and position information. Finally, the hole fusion module was integrated into the semantic branch channel, enhancing the ability of network to extract the feature information. Experimental results show that the proposed algorithm improves the edge detection performance of photovoltaic panel images. Compared to the holistically-nested edge detection (HED), richer convolutional features (RCF) and Fully convolutional network (FCN) algorithms, the  $F_1$  value of the proposed algorithm was increased by 2.83%, 0.37% and 1.54%, respectively, which obtained the clearer crack images.

**Keywords:** crack detection; multi-scale; attention mechanism; dual-channel network; hole fusion

## 0 引言

在图像处理和计算机视觉中, 边缘检测是一个必不可少的基本步骤。它是图像分割、特征提取和目标区域识别等图像处理的基本任务。如果边缘检测有效, 原始图像中包含的信息内容可以大大简化。然而, 通常并不总是能够从复杂的图像中获得足够好的边缘, 也就是说, 很难从边缘曲线不连接、边缘片段缺失或虚假边缘中提取边缘。因

此, 开发一种有效的边缘检测方法是有意義的。

边缘检测方法可以分为两种: 传统检测方法和基于新型理论技术的结构化边缘检测算法。传统方法使用各种微分算子, 如 Sobel<sup>[1]</sup>、Prewitt<sup>[2]</sup> 和 Canny<sup>[3]</sup> 等。另一种方法是基于小波变换<sup>[4]</sup>、数学形态学<sup>[5]</sup>、遗传算法<sup>[6]</sup>、模糊数学<sup>[7]</sup>、组合优化理论<sup>[8]</sup> 和深度学习等新型技术的边缘检测算法<sup>[9]</sup>。Wang<sup>[10]</sup> 等提出一种新的道路边缘检测方法, 该方法结合了颜色特征筛选、Canny 算子和霍夫变化的原理, 首先

收稿日期: 2023-02-20; 修回日期: 2023-03-17。

基金项目: 江苏省研究生实践创新计划项目(SJ CX21\_1272)。

作者简介: 强浩(1976-), 男, 博士, 副教授, 硕士研究生导师。

引用格式: 强浩, 叶波, 唐文祺. 基于双通道多尺度注意力机制的光伏板裂缝检测方法[J]. 计算机测量与控制, 2023, 31(12): 84-89, 264.

对包含道路信息的彩色图像进行颜色空间转换和颜色特征筛选, 利用 Canny 算子进行边缘检测。通过将结果直线检测, 同时基于霍夫变换原理对道路边缘进行检测和标记。Zheng<sup>[11]</sup>等在 Canny 算子边缘检测的基础上, 用形态学滤波代替高斯滤波, 并在四个方向计算梯度幅值以降低噪声的影响。Widiyanto<sup>[12]</sup>等提出基于量子 Canny 增强的医学图像边缘检测方法, 该方法重点介绍了通过观察相邻像素值的强弱来生成梯度幅值的方法, 从而提高边缘检测结果的质量。这些方法是通过利用图像的一阶或二阶梯度信息提取图像的边缘的方法。这一类方法的实时性好, 但容易受噪声、光照等因素的影响。此类方法似乎精度较差, 因此很难适应今天的应用。

随着深度学习技术的发展, 卷积神经网络 (CNN, convolutional neural network)<sup>[13]</sup>成为了重要的工具, 卷积神经网络在自动学习图像的高级特征具有强大的能力等优势, 利用卷积神经网络进行边缘检测能提高的边缘检测性能, 目前运用卷积神经网络体系结构已成为一种新的边缘检测趋势。

随着计算机的算力提升, 基于深度学习的边缘检测算法成为主流方法<sup>[14-15]</sup>。文献 [16] 在实验室中生成了高分辨率 EL 图像数据, 包含图像的裂缝和光伏组件的缺陷, 并提出了一种分类使用的简单卷积神经网络, 准确率达到 99%。文献 [17] 提出了一种自动缺陷检测方法, 该方法使用深度卷积神经网络进行 EL 图像分类。利用太阳的位置估计太阳能组件的输出功率, 将神经网络成功地应用于检测太阳能组件的功率损耗。文献 [18] 提出了一种区域注意网络, 将 CAN 模型嵌入到 Faster R-CNN 中的区域提议网络中, 提取出更精细的缺陷区域, 从而构建了一种新的端到端 Faster R-PAN-CNN 框架, 用于检测原始 EL 图像中的缺陷。最近几年研究者首先利用卷积层、全连接层来获得初步局部边缘特征图, 然后使用非极大值抑制等后处理方法获取边缘图像。然而卷积神经网络体系结构只使用最终的卷积层或在池化层以前的层, 而忽略了中间层的特征。由于更丰富的卷积带来的卷积特征对于许多视觉任务是非常有效的, 因此本文致力于研究对中间层的多级利用, 开发更深层次的网络。

针对这些问题, 本文提出了一种基于双通道多尺度注意力机制的光伏板裂缝检测方法, 该方法充分利用图像的多尺度和多层次信息, 全面地进行图像到图像的预测, 实现对低级边缘、边界、目标轮廓的检测。首先构架了双通道主干网络, 包含了语义分支与空间细节分支。其次提出多尺度注意力机制模块, 通过对通道、高、宽 3 个维度变换实现特征权重重新分配和互补融合, 进行多级利用; 最后将空洞融合模块嵌入网络中, 使各网络层之间最大程度的传递和使用特征信息特征提取能力大大提高, 在增强网络性能的同时, 减少网络噪声的干扰。

## 1 双通道多尺度注意力机制的网络模型

本节首先在 1.1 节中介绍了双通道网络整体结构, 其

次在 1.2 节中详细介绍了多尺度注意力机制模块, 此外, 在 1.3 节中介绍了空洞融合模块, 最后, 在 1.4 节中介绍了损失函数。

### 1.1 网络整体结构

网络主干由双通道组成, 分别为语义分支通道和空间细节分支通道, 不同的分支通道对应不同的功能, 空间细节分支通道由 3 个卷积块组成, 该通道获取图片的低级特征与浅层次的空间细节; 语义分支由 5 个深度卷积块组成, 通过快速下采样策略, 扩大感受野, 该通道获取图片的高级语义, 提高网络特征表示水平。同时在空间细节分支与语义分支中嵌入多尺度注意力机制模块, 将语义分支的最后两个卷积块的侧输出采用空洞融合方法。在增强网络性能的同时, 减少网络噪声的干扰。双通道多尺度注意力机制的网络模型如图 1 所示。

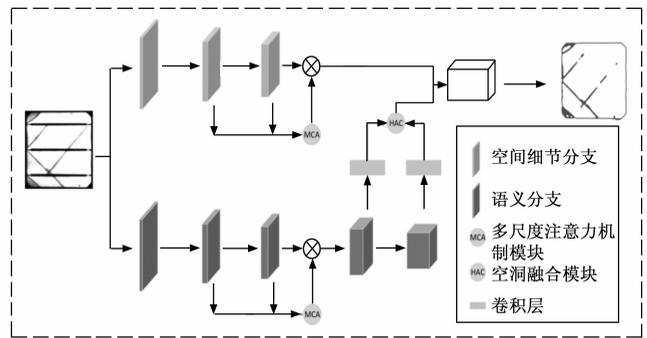


图 1 双通道多尺度注意力机制的网络模型整体结构

空间细节分支主干由 3 个卷积块组成, 语义分支主干由 5 个深度卷积块组成, 深度卷积块使用两种不同的下采样方式来缩小特征表示。然后将两个分支的输出特征连接起来作为输出。该结构具有高效的计算成本和有效的特征表达能力。

表 1 空间分支与语义分支结构组成表

stage	空间分支主干					语义分支主干				
	Conv Block	$k$	$c$	$s$	$r$	Conv Block	$k$	$c$	$s$	$r$
$S_1$	ConV	3	64	2	1	Deep ConV	3	16	2	1
	ConV	3	64	1	1	Deep ConV	3	16	1	1
$S_2$	ConV	3	128	2	1	Deep ConV	3	32	2	1
	ConV	3	128	1	2	Deep ConV	3	32	1	1
$S_3$	ConV	3	256	2	1	Deep ConV	3	64	2	1
	ConV	3	256	1	2	Deep ConV	3	64	1	1
$S_4$						Deep ConV	3	128	2	1
						Deep ConV	3	128	1	2
$S_5$						Deep ConV	3	256	2	1
						Deep ConV	3	256	1	2

其中: ConV 为卷积块, Deep ConV 为深度卷积块,  $k$  为卷积核,  $c$  为通道数,  $s$  为步长,  $r$  为重复次数。

理论上, 增加网络的深度或宽度可以提取到更丰富的细节与抽象特征, 但简单地增加层数操作容易出现梯度爆炸或梯度弥散的问题。传统方法, 如归一化初始化和批处

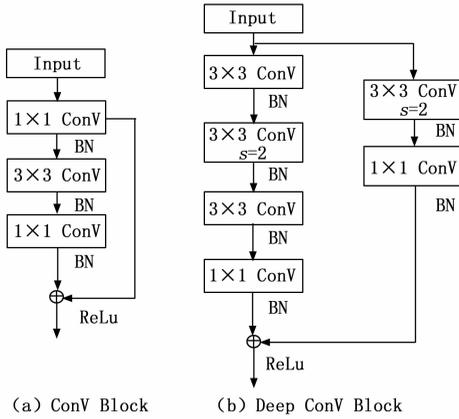


图 2 主干网络卷积块

理归一化，可以解决梯度问题，但会降低网络性能。为了解决这个问题，研究人员提出了一种残差网络，该网络采用“shortcut, skip connection”来建立前层和后层之间的联系，类似于 Highway 网络的思想。这种方法可以帮助梯度反向传播，从而训练出更深层次的神经网络，克服了深层神经网络性能下降的缺点。因此主干网络选用残差卷积块<sup>[19]</sup>，并在此基础上更新为深度卷积块。深度卷积块沿用残差卷积块的想法，在残差路径上增加卷积层，充分利用残差路径，提升网络的卷积深度。

残差卷积块由三个卷积层与一条残差路径组合而成，其中卷积核的大小分别为  $1 \times 1$ 、 $3 \times 3$ 、 $1 \times 1$ ，在每个卷积层后均进行批量归一化，在融合后有 ReLU 激活层操作。

深度卷积块由两条路径组合而成，其中主路径由四个卷积层组成，其中卷积核的大小分别为  $3 \times 3$ 、 $3 \times 3$ 、 $3 \times 3$ 、 $1 \times 1$ 。残差路径上由两个卷积层，其中卷积核的大小分别为  $3 \times 3$ 、 $1 \times 1$ ，在每个卷积层后均进行批量归一化，在融合后有 ReLU 激活层操作。

### 1.2 多尺度注意力机制模块

为了进一步提取网络的深层特征，提高模型的深度与识别精度，受多尺度学习算法结构的启发，本文在注意力机制模块<sup>[20]</sup>上改进，提出了多尺度注意力机制模块（MCA, multi-coordinate attention）。如图 4 所示，该模块在捕捉跨通道信息的同时，还能够捕捉方向感知和位置感知的信息，有利于网络快速识别和定位目标区域；其次注意力机制模块灵活且轻量，可以容易被插入经典模块，如 MobileNetV2<sup>[21]</sup>提出的 inverted residual block 和 MobileNeXt<sup>[22]</sup>提出的 sandglass block，来通过强化信息表示的方法增强特征；最后，作为一个预训练模型，注意力机制模块可以在轻量级网络的基础上给下游任务带来巨大的增益，特别是那些存在密集预测的任务（如语义分割）。

利用并行网络，并且每个网络通过利用感受野的大小设定不同的卷积核，获得的结果是多尺度的。将输入图像输入多个网络，得到多个特征结果，直接体现了多尺度思想。从注意力机制通道和空间的角度考虑，构建通道之间的关联程度与空间像素直接的依赖关系使得网络中的细节特征得到更多的关注。本文在此基础上增加了维度变换的

思想，通过对图像的  $C \times H \times W$  三个维度的两两维度变换，在维持维度不变的情况下，对注意力机制的深度大大提高。图 3 为多尺度学习方法。

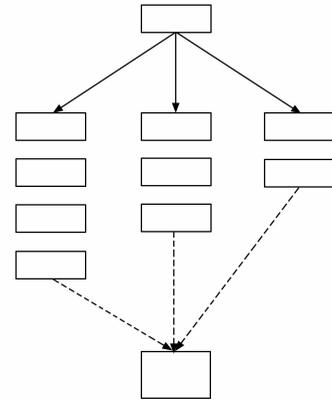


图 3 多尺度学习方法

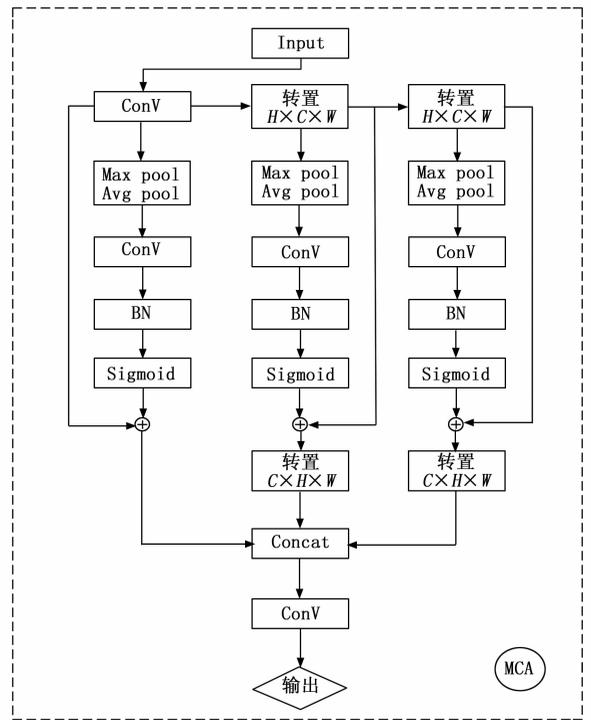


图 4 多尺度注意力机制模块

多尺度注意力机制是将输入的特征维度进行变换，首先将  $F_1 = C \times H \times W$  变换为  $F_2 = H \times C \times W$ ，与  $F_3 = W \times H \times C$ ，其次对输入的特征  $F_1 = C \times H \times W$  经过最大池化与平均池化得到了  $F_{1max} = 1 \times H \times W$  与  $F_{1avg} = 1 \times H \times W$ ，然后将  $F_{1max}$  与  $F_{1avg}$  基于通道拼接起来，得到  $F_{1max+avg} = 2 \times H \times W$  的特征图，对特征图进行卷积压缩为通道数为 1 的特征图，再通过 BN 归一化、Sigmoid 函数激活运算后获得空间权重值，将空间权重值加权到通道的特征  $F_1$  上，获得了空间权重特征图  $M_{s1} = 1 \times H \times W$ 。同时经过相同的变换获得空间权重特征图  $M_{s2}$  与  $M_{s3}$ ，将两张空间权重特征图  $M_{s2}$  与  $M_{s3}$  转置与拼接融合操作获得多尺度空间权重特征图  $M_s$ ，

$M_s$  计算公式如式 (1) 所示:

$$M_S = M_{S1} + M_{S2} + M_{S3} = \sigma\{\text{conv}[F_{1\max} \oplus F_{1\text{avg}}]\} + \{\sigma\{\text{conv}[F_{2\max} \oplus F_{2\text{avg}}]\}\}^{TT} + \{\sigma\{\text{conv}[F_{3\max} \oplus F_{3\text{avg}}]\}\}^T \quad (1)$$

其中:  $\sigma$  表示激活函数 Sigmoid,  $\oplus$  表示拼接操作, conv 表示卷积操作。

### 1.3 空洞融合模块

在神经网络中通常离不开下采样操作, 连续的下采样会导致特征图的空间分辨率严重下降, 而且如果压缩程度较高, 还会给后续的上采样或反卷积还原至原图大小增加难度。空洞卷积<sup>[23]</sup>很好的优化了这个问题, 在不池化和相同的计算条件下, 增大了感受野, 提高网络的表达能力。但空洞卷积在输入特征层中的采样点分布相对稀疏, 大量的局部细节特征很容易被丢失, 导致网络对于小尺度的目标和局部边界的分割效果不佳。针对空洞卷积的优缺点, 本文使用空洞融合模块, 不同卷积层的特征图包含的大量不同的语义特征, 将高层与低层的特征图分别采用不同空洞率的卷积核, 用不同扩张率空洞卷积得到不同的感受野, 再通过融合方法将特征图拼接, 有效提取分布在不同范围内的细节信息。进一步提高特征的维度, 获得输出的特征图能够有更多的局部细节。提升网络的深度与精度。如图 5 所示, 将主网络的两层分别采用扩张率为 1、2 的空洞卷积和全局池化操作进行初步的多尺度特征提取, 得到了不同范围内的细节信息。其次将主干网络中的两个不同通道四个不同尺度的特征信息进行多尺度特征输出进行通道连接, 得到的特征进行通道融合。

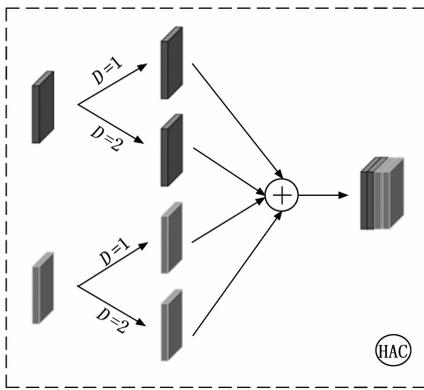


图 5 空洞融合模块

### 1.4 损失函数

由于光伏板裂缝检测只有裂缝和背景两个类别, 裂缝区域相较于整个背景占据小部分面积, 对于这种背景所占比例大, 物体所占比例较小的不平衡样本, 是一个二分类问题, 因此本文采用二分类交叉熵 (binary cross entropy) 与 Dixeloss 联合作为本文的损失函数。Dixeloss 可以缓解样本中前景背景 (面积) 不平衡带来的消极影响, 但更关注对前景区域的挖掘, 会带来损失饱和问题, 因此联合二分类交叉熵作为本文的损失函数能很好地缓解这一问题。

$$L = L_{\text{BCE}} + L_{\text{DL}} \quad (2)$$

$$L_{\text{BCE}} = \frac{1}{N} \sum_{i=1}^N -[r_i \cdot \log(p_i) + (1 - r_i) \cdot \log(1 - p_i)] \quad (3)$$

$$L_{\text{DL}} = 1 - \frac{2 \sum_{i=1}^N p_i r_i}{\sum_{i=1}^N p_i + \sum_{i=1}^N r_i} \quad (4)$$

其中:  $N$  为样本总量,  $r_i$  表示第  $i$  个像素点的标签值,  $p_i$  表示为第  $i$  个像素点的预测值。

## 2 实验结果及分析

本节首先在 2.1 节中介绍了实验配置, 其次在 2.2 节中详细介绍了数据集, 此外, 在 2.3 节中介绍了评价指标, 最后, 在 2.4 和 2.5 节中通过对比实验与消融实验验证本文算法的性能。

### 2.1 实验配置介绍

本实验使用基于 PyCharm 集成开发环境下使用 Python 3.8 开发的。软件实现的主要框架为 Tensorflow2.0 深度学习框架, 通过 matplotlib 模块进行可视化。硬件环境 CPU 为 Inter core i9-6700HQ, GPU 为 NVIDIA GeForce GTX 2080Ti 显卡。

### 2.2 数据集介绍

太阳能电池板采用了原子层沉积等技术对电池进行钝化, 使背面的反射率较高, 当用长波的光照射到电池板背面, 缺陷的区域的反射率会降低, 电池板背面会出现明暗不同的区域。利用这个原理, 反映在图像中, 根据明暗程度可快速定位缺陷区域, 因此本文采用电致发光数据集进行实验。

本实验所使用的数据集来源于太阳电池 EL 图像数据集, 该数据集是一个公共数据集, 包含了像素大小为  $300 \times 300$  的电致发光图片。数据集中包含了多种不同程度的缺陷图片, 包括隐裂、碎片以及没有缺陷的 EL 图片。这些图片已经过标准化处理, 以确保数据的一致性。在数据预处理的过程中, 随机选取了 600 张电致发光图片, 然后将这些图片随机分成了训练集、测试集和验证集。这种数据集的使用可以确保实验结果的科学性和准确性, 并且可以有效地验证模型的泛化能力。

### 2.3 评价指标

为了对实验结果进行客观的定量分析, 选取精确率  $P$  (Precision)、召回率  $R$  (Recall)、均衡平均数 ( $F_1$ ) 作为模型性能的评价指标。精确率表示正确检测的裂缝像素原本是正确像素的比例。召回率表示正确检测的裂缝像素占有所有裂缝像素的百分比。精确率和召回率是评价模型好坏的重要指标, 根据精确率与召回率计算出的  $F$  值作为性能评估的总体指标, 均衡平均数越高说明模型质量越好。  $P$ 、 $R$ 、 $F_1$  如式 (5) ~ (7) 所示:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (5)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (6)$$

$$F_1 = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (7)$$

其中： $TP$  (truepositive) 表示真正值，即模型将正确的裂缝检测为裂缝； $FP$  (falsepositive) 表示假正值，即模型将背景错误的检测为裂缝； $FN$  (falsenegative) 表示假负值，即模型错误的将裂缝检测为背景。

### 2.4 对比实验

为了充分评估本文提出的双通道多尺度注意力机制网络模型在裂缝检测中的性能，本节通过对比实验在同一光伏板数据集上独立训练三种网络 (HED<sup>[24]</sup>、FCN<sup>[26]</sup>、RCF<sup>[27]</sup>)，比较三种网络对光伏板边缘检测的性能。

不同模型在电致发光数据集上的 P-R 曲线如图 6 所示。P-R 曲线是以精确率  $P$  和召回率  $R$  作为横纵坐标的曲线，通过 P-R 曲线的整体表现，能够对模型进行更加全面的评估。曲线所占面积越大，表明性能越好。由各模型在电致发光数据集上的检测结果可知，HED 与 RCF 网络的精确率  $P$  分别为 66.51%、67.80%，召回率  $R$  分别为 76.96%、87.73%， $F_1$  值分别为 73.35%、75.81%。HED 网络基于 VGG16<sup>[25]</sup> 网络基础之上，在 VGG16 网络每个阶段的最后一个卷积层之后添加侧输出层，为了节约网络训练的内存与时间成本，去掉了最后一个池化层和之后的全连接层。HED 借助于 VGG 网络强大的特征提取能力，对图像进行多尺度多层次的学习，直接对整幅图像进行操作。在侧输出层通过深度监督，将不同尺度的侧输出结果进行融合，最后得到了较为优秀的边缘检测结果。然而网络的深度加深的时候，特征的分辨率也在逐渐下降，这会导致边缘细节的丢失，在边缘检测任务中表现尤为明显。为了解决这个问题，RCF 网络对 HED 网络进行了改进。RCF 网络采用全卷积网络，去掉了网络中的最后一个池化层和全连接层，并将不同层的特征进行融合。此外，RCF 网络还提出了一种新的损失函数。从实验结果也能看出 RCF 网络性能优于 HED 网络。

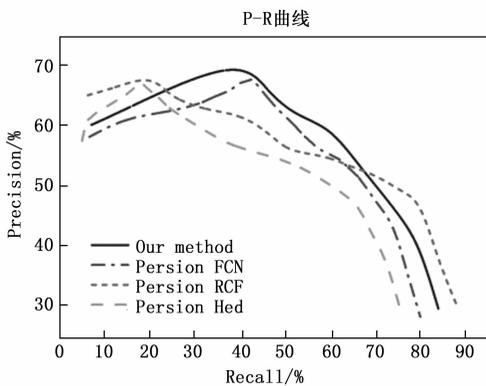


图 6 不同模型在电致发光数据集的 P-R 曲线

FCN 网络的精确率  $P$  为 68.22%，召回率  $R$  为 81.68%， $F_1$  值为 74.64%。FCN 网络通过反卷积操作对最后一个卷积层的特征图上采样，使特征图的尺寸恢复到与输入图像尺寸相同，以产生一个预测结果。该方法保留了原始输入图像的空间信息，并在上采样的特征图上进行像素分类。然而，这种方法忽略了像素之间的关系，缺乏空间一致性，因为它没有使用像素之间的空间规整步骤。

本文提出的多尺度注意力机制网络模型考虑了坐标空间的特性，捕捉跨通道信息、方向感知和位置感知的信息。从图 6 中可以看出，本文提出的网络模型的实验结果曲线在图像的最上方，曲线所占面积最大，表明性能最好。从表 2 中可以看出精确率  $P$  达到 69.1%，召回率  $R$  达到 84.9%， $F_1$  最高达到 76.18%，相较 HED、RCF 与 FCN 算法， $F_1$  值提升了 2.83%、0.37% 与 1.54%，获得了较为清晰的裂缝图像。表明本文提出的双通道多尺度注意力机制网络模型的提取裂缝特征的能力高，抗干扰能力好，网络性能好。

表 2 电致发光数据集对比实验 %

Methods	Precision	Recall	$F_1$
HED	66.51	76.96	73.35
RCF	67.80	87.73	75.81
FCN	68.22	81.68	74.64
Our method	69.15	84.92	76.18

### 2.5 消融实验

为了验证本文设计的多尺度注意力机制模块对于实验结果性能的提升效果，本节通过在同一光伏板数据集上进行消融实验，比较多尺度注意力机制模块与空洞融合模块对网络的性能提升。包含了三个实验序号及其对应的多尺度注意力机制模块和空洞融合模块的组合方式，以及在这些组合方式下的模型评估指标精确率、召回率和  $F_1$  均衡数。所有参数设置、学习率和损失函数保持一致，消融实验分为三组，第一组实验为双通道网络，不包含多尺度注意力机制模块和空洞融合模块，第二组实验在第一组的基础上包含空洞融合模块，第三组实验在第二组的基础上包含多尺度注意力机制模块。具体结果见表 3。

表 3 电致发光数据集消融实验结果

实验序号	多尺度注意力机制模块	空洞融合模块	Precision / %	Recall / %	$F_1$ / %
1	N	N	64.43	78.05	70.81
2	N	Y	66.56	80.14	72.54
3	Y	Y	69.15	84.92	76.18

如表 3 所示，对比实验 1 和实验 2，采用空洞融合时，网络的精确率提升了 2.13%，召回率提升 2.09%， $F_1$  均衡平衡数提升了 1.73%；对比实验 2 和实验 3，在实验二的基础上增加了多尺度注意力机制模块，网络的精确率提升了 2.59%，召回率提升 4.78%，均衡平衡数提升了 3.64%，实验三的三个指标都取得了最高的表现。从图 7 中可以看出，实验 1 和实验 2 检测的裂纹有断点不连续，有部分裂缝检测不出，并且将部分背景误检测为裂纹，并且实验 1 的裂缝检测重叠部分较厚。实验 3 中检测的裂纹连续，较为平整，将背景与裂纹更好的分割。

综上所述，本文提出的多尺度注意力机制模块与空洞融合模块对模型性能的提升有积极作用，同时将两个模块组合实验能够达到最优的检测性能，能够更加准确地识别

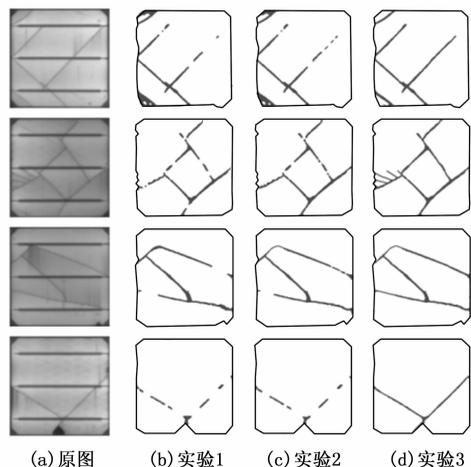


图 7 电致发光数据集消融实验检测图

和定位目标区域。

### 3 结束语

针对本文提出了一种基于双通道多尺度注意力机制的光伏板裂缝检测方法, 设计了双通道主干网络, 包含语义分支与空间细节分支, 在空间细节分支与语义分支中嵌入多尺度注意力机制模块, 将语义分支的最后两个卷积块的侧输出采用空洞融合方法。网络模型有效地提取了裂缝特征, 抑制了背景因素的干扰。实验结果表明, 本文的方法优于经典的边缘检测算法, 在电致发光数据集中的消融实验体现多尺度注意力机制模块与空洞融合模块对网络有提升, 一定程度上提高了裂缝细节恢复和空间位置信息定位能力, 能够提高裂缝检测的性能。

缺陷检测作为一个非常重要的应用领域, 随着技术的进步, 网络的精度将不断提高, 并且能够应用于越来越多的领域, 在未来几年将继续发挥重要作用。未来的可以将缺陷检测将逐渐从基于图像的检测向基于视频的检测转变, 并且可以使用更多的智能算法来提高精度和效率。后续对于研究裂缝检测的研究, 可以对数据集扩充, 继续优化模型结构, 提高模型的计算效率、检测能力和泛化能力。未来我将更加专注于尝试在更多的缺陷识别上执行实验评估。

#### 参考文献:

[1] KITTLER J. On the accuracy of the Sobel edge detector [J]. *Image and Vision Computing*, 1983, 1 (1): 37-42.

[2] TORRE V, POGGIO T A. On edge detection [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1986 (2): 147-163.

[3] CANNY J. A computational approach to edge detection [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1986 (6): 679-698.

[4] 武钰瑾, 赵凤霞, 辛传福, 等. 图像清晰度的小波变换抗噪评价算法 [J]. *机械设计与制造*, 2022 (4): 46-49.

[5] 郑雅茹. 基于数学形态学算法的遥感图像边缘去噪方法 [J].

*自动化与仪器仪表*, 2022 (5): 36-39.

[6] 王改云, 郭智超, 路皓翔, 等. 融合遗传算法的多域值分块低照度图像增强算法 [J]. *光子学报*, 2022, 51 (4): 393-406.

[7] 李翠芳, 聂生东. 基于模糊数学的医学图像处理与分析方法 [J]. *中国医学物理学杂志*, 2011, 28 (4): 2750-2753.

[8] ZHANG J Q, LI X Y, LI L Y, et al. Landsat 8 remote sensing image based on deep residual fully convolutional network [J]. *Laser & Optoelectronics Progress*, 2020, 57 (10): 102801.

[9] JIAO A B, HE M, LUO H B. Research on significant edge detection of infrared image based on deep learning [J]. *Infrared Technology*, 2019, 41 (1): 72-77.

[10] WANG S, WU S, WANG X, et al. A canny operator road edge detection method based on color features [C] // *Journal of Physics: Conference Series*. IOP Publishing, 2020, 1629 (1): 012018.

[11] DENG C X, WANG G B, YANG X R. Image edge detection algorithm based on improved canny operator [C] // *2013 International Conference on Wavelet Analysis and Pattern Recognition*. IEEE, 2013: 168-172.

[12] WIDIYANTO S, SUNDANI D, KARYANTI Y, et al. Edge detection based on quantum canny enhancement for medical imaging [C] // *IOP Conference Series: Materials Science and Engineering*. IOP Publishing, 2019, 536 (1): 012118.

[13] GU J, WANG Z, KUEN J, et al. Recent advances in convolutional neural networks [J]. *Pattern Recognition*, 2018, 77: 354-377.

[14] PARK J K, KWON B K, PARK J H, et al. Machine learning-based imaging system for surface defect inspection [J]. *International Journal of Precision Engineering and Manufacturing-Green Technology*, 2016, 3: 303-310.

[15] TAO X, ZHANG D, MA W, et al. Automatic metallic surface defect detection and recognition with convolutional neural networks [J]. *Applied Sciences*, 2018, 8 (9): 1575.

[16] JAZAYERI K, UYSAL S, JAZAYERI M. Determination of power losses in solar panels using artificial neural network [C] // *2013 Africon*, IEEE, 2013: 1-6.

[17] SU B, CHEN H, CHEN P, et al. Deep learning-based solar-cell manufacturing defect detection with complementary attention network [J]. *IEEE Transactions on Industrial Informatics*, 2020, 17 (6): 4084-4095.

[18] HAN H, GAO C, ZHAO Y, et al. Polycrystalline silicon wafer defect segmentation based on deep convolutional neural networks [J]. *Pattern Recognition Letters*, 2020, 130: 234-241.

[19] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016: 770-778.

[20] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 7132-7141.

(下转第 264 页)