

# 基于元迁移的太阳能电池板缺陷图像超分辨率重建方法

周颖<sup>1,2</sup> 常明新<sup>1</sup> 叶红<sup>1</sup> 张燕<sup>1</sup>

1 河北工业大学人工智能与数据科学学院 天津 300130

2 河北省控制工程技术研究中心 天津 300130

(Zhouying2007@163.com)

**摘要** 针对太阳能电池板隐裂缺陷在进行光学检测时存在的特征不明显问题,以及小样本导致的训练不充分问题,提出了基于元迁移的太阳能电池板缺陷图像超分辨率重建方法,采用联合训练方法,利用内部图像和外部大规模图像信息分别作为不同阶段的训练数据。首先将引入的大量数据用于模型的初步训练,学习外部大规模数据的公共特征,然后通过元学习模型MAML进行多任务训练,为快速适应小样本无监督任务寻找一个适合图像内部学习的初始参数,提高模型的泛化能力,最后将预训练参数迁移至改进的ZSSR中进行自监督学习。在DIV2K、Set5、BSD100和太阳能电池板电致发光成像数据集上进行训练,实验结果表明,与传统的CARN、RCAN、IKC、ZSSR方法相比,该方法具有更高的峰值信噪比,最高达到36.66,参数量更小,相比ZSSR降低了70000,图像重建时间更短,相比CARN降低了0.51s,具有更好的重建效果,更高的重建效率。

**关键词:** 太阳能电池板缺陷;超分辨率重建;元学习;卷积神经网络;DIV2K训练集

中图分类号 TP391

## Super Resolution Reconstruction Method of Solar Panel Defect Images Based on Meta-transfer

ZHOU Ying<sup>1,2</sup>, CHANG Ming-xin<sup>1</sup>, YE Hong<sup>1</sup> and ZHANG Yan<sup>1</sup>

1 School of Artificial Intelligence and Data Science, Hebei University of Technology, Tianjin 300130, China

2 China Hebei Control Engineering Research Center, Tianjin 300130, China

**Abstract** It is difficult to detect solar panel crack defect due to low resolution and contrast, and few samples lead to inadequate training problem. To solve these problems, this paper puts forward the super resolution reconstruction method of solar panel images based on meta-transfer, and we adopt joint training method, that is, the internal image and external large-scale image information are used as the different stages of training data. First, a large amount of data is used to pretrain the model to learn the external public characteristics of large-scale data. Then, we use the meta-learning model MAML for multi-task training to find initial parameters, which are suitable for the unsupervised task of few samples to improve the generalization ability of the model. Finally, we put pretrained parameters in improved ZSSR to improve the Self-supervised Learning. Through DIV2K, Set5, BSD100 and solar panels electroluminescent imaging training dataset, the experimental results show that compared with the traditional CARN, RCAN, IKC and ZSSR, this method has the higher peak signal-to-noise ratio, up to 36.66, and fewer parameters, compared with ZSSR, the number of parameters decreases by 70 000 with shorter computation time, and compared with CARN, the computation time decreases by 0.51 s. It is obvious that our method has the better reconstruction effect, the higher reconstruction efficiency.

**Keywords** Solar panel defects, Super-resolution reconstruction, Meta-learning, Convolutional neural network, DIV2K training set

太阳能电池板在制备过程中存在实心黑、隐裂、断栅、阴影、开焊等缺陷,图1为5种缺陷的电致发光(Electroluminescent, EL)图像。这些缺陷对电池的转换效率和使用寿命有着严重的影响,严重时将危害组件甚至光伏发电系统的稳定性。

因此太阳能电池板缺陷检测是电池板生产过程的重要步骤。深度学习是目前主流的缺陷检测方法,而特征的有效提取对缺陷的检测起着决定性的作用,因此如何高效地提取特征成为重要的研究方向。Jiang等<sup>[1]</sup>针对室外运行的太阳能电池

到稿日期:2021-01-29 返修日期:2021-05-02

基金项目:国家自然科学基金(60741307);河北省创新能力提升计划项目(18961604H)

This work was supported by the National Natural Science Foundation of China(60741307) and Innovation Capability Enhancement Program Project of Hebei Province(18961604H).

通信作者:张燕(yzhangz@163.com)

板裂纹检测问题,提出一种改进的神经网络,其训练过程使用欠采样与过采样技术,解决了正负样本不平衡的问题,能够更好地满足特征多样性、均衡性,准确率达到96.7%。Chen等<sup>[2]</sup>在Segnet网络框架上使用空洞卷积替代池化层,在增大感受野的同时保留了图像的边缘信息,显著提高了检测的准确率。Guo等<sup>[3]</sup>自主搭建卷积神经网络检测算法,通过评估模型深度和核大小对特征提取的影响,选出最佳网络模型,其准确率达到95.45%,相比其他算法具有更高的检测精度。由于太阳能电池板隐裂、断栅等缺陷,导致面积较小、位置不定、不易识别且样本较少,因此太阳能电池板的缺陷检测难度大。针对此问题,本文将元学习迁移至检测图像超分辨率重建中,从数据集的构建入手,使重建后的图像特征更加明显,更加利于缺陷的检测。另外,元迁移学习在一定程度上缓解了小样本数量不足的问题。




图1 EL的5种缺陷

Fig.1 Five kinds of defects of EL images

## 1 图像超分辨率重建

### 1.1 零样本超分辨率重建

图像超分辨率重建分为有监督方法和无监督方法。零样本超分辨率重建(“Zero-Shot” Super-Resolution, ZSSR)<sup>[4-6]</sup>属于无监督超分方法,不需要使用额外的数据集进行预训练,仅利用单一图片内部信息的重复性训练图像即可重建网络。如图2所示,对一张具有低分辨率隐裂缺陷的太阳能电池板图像进行超分辨率图像重建时,先对该图片 $I$ 进行下采样,作为重建网络的输入,将输出结果与原图 $I$ 进行比较,学习二者之间的超分辨率模型,再使用ZSSR模型对低分辨率图像进行超分辨率重建。




图2 ZSSR训练过程

Fig.2 ZSSR training process

图2中, $I \downarrow_s$ 表示由测试图像 $I$ 下采样得到, $I \uparrow_s$ 表示由测试图像 $I$ 上采样得到。

ZSSR具有很高的灵活性,能对非理想条件下的图像

(老旧历史照片、网络照片、手机拍摄照片)进行处理,不需要进行预训练,没有任何输入尺度限制,因此可以很容易地适应测试图像的条件。但ZSSR也有局限性:经实验结果可知,在隐裂的重建过程中需要进行数千次的反向梯度更新,其效果才显著,因此该过程需要消耗大量的时间;训练没能利用大规模的外部数据,仅依赖内部结构和信息,使得样本总数缺乏,容易出现过拟合、泛化能力较差问题。针对上述的局限性,将大规模训练作为初始训练,随后通过模型无关元学习的多任务训练得到预训练模型,增加公共特征信息,提高模型的重建效率和泛化能力;使用深度可分离卷积替代普通卷积对ZSSR进行改进,可以进一步加快训练速度。

### 1.2 模型无关元学习

元学习(meta-learning)<sup>[7]</sup>指通过多个训练任务得到一份适应性很强的初始化参数,通过目标样本训练微调得到新任务模型,解决了深度学习难以通过少量样本快速学习新概念的问题。

模型无关元学习(Model-Agnostic Meta-Learning, MAML)<sup>[8-10]</sup>随机抽取多任务用于模型的训练,通过多任务训练中梯度的加权来更新参数。其仅用少量数据进行10次以内的梯度更新就能适应新的任务。本文采用MAML算法对经过大规模数据训练后的模型进行进一步训练,使学习模型快速适应新任务的调整方法,得到预训练模型。算法流程如算法1所示。

#### 算法1 模型无关元学习

Require: 多任务分布  $p(T)$ , 超参数步长  $\alpha, \beta$

1. 随机初始化  $\theta$
2. while not down do
3. 任务的采样:  $T_i \sim p(T)$
4. for all  $T_i$  do
5. 追对  $K$  个样本对  $\nabla_{\theta} L_{T_i}(f_{\theta})$  进行评估
6. 使用梯度下法:  $\theta'_i = \theta - \alpha \nabla_{\theta} L_{T_i}(f_{\theta})$  计算自适应参数
7. end for
8. 更新  $\theta_i \leftarrow \theta - \beta \nabla_{\theta} \sum_{T_i \sim p(T)} L_{T_i}(f_{\theta'_i})$
9. end while

其中, $p(T)$ 表示训练集中任务的分布,每个任务为高分辨率、低分辨率图像组成的图像对; $\alpha$ 和 $\beta$ 为学习率。步骤1先进行参数初始化 $\theta$ ;步骤3表示对若干个任务进行采样得到 $T_i$ ;步骤4-7得到多个任务第一次梯度更新结果 $\theta'_i$ ,如式(1)所示:

$$\theta'_i = \theta - \alpha \nabla_{\theta} L_{T_i}(f_{\theta}) \quad (1)$$

更新次数为采样的任务数;步骤8为模型参数的更新过程,如式(2)所示,最终得到学习到的模型 $M_{meta}$ 。

$$\theta \leftarrow \theta - \beta \nabla_{\theta} \sum_{T_i \sim p(T)} L_{T_i}(f_{\theta'_i}) \quad (2)$$

### 1.3 基于元迁移学习的超分辨率重建

本文将MAML引入ZSSR中,提出一种基于元迁移学习的超分辨率重建方法(Meta-Transfer Super-Resolution, MTSR),在ZSSR的基础上增加一个预训练步骤MAML。首先通过大量外部数据学习得到公共特征,将该特征传入

元学习模型 MAML 中进行多任务学习,补充模型特征并提高模型的适应性和泛化能力,该过程对参数进行一次更新,以获得预训练模型;然后对预训练模型进行内部训练,将预训练参数传入改进的 ZSSR 模型中,其输入为太阳能电池板缺陷图像,使用目标图像的内部信息进行模型的二次更新,得到最优模型,用于最终的超分辨率图像重建任务。该重建方法的流程如图 3 所示。实验结果证明,该方法的重建效果优于其他图像重建方法,并且具有更高的效率。

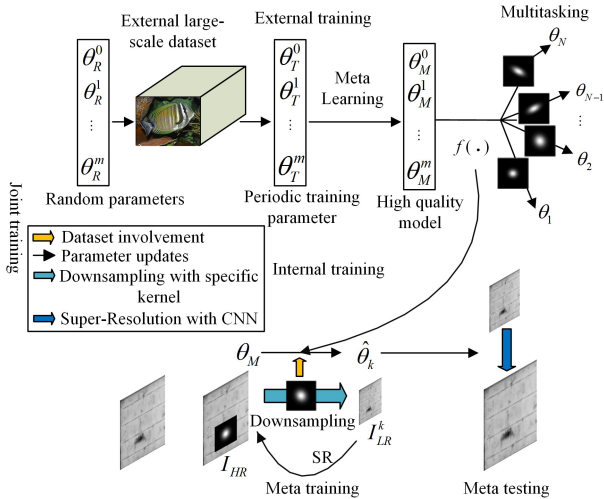


图 3 MTSR 重建方法

Fig. 3 MTSR reconstruction method

## 2 联合训练方法

### 2.1 外部训练

如图 3 所示,联合训练方法分为外部训练和内部训练,外部训练先随机初始化参数,采用 DIV2K<sup>[11]</sup>数据集作为外部大规模数据,该数据集包含 1000 张高分辨率图片  $I_{HR}$ ,使用双三次插值法(Bicubic)<sup>[12]</sup>将高分辨率图像退化到低分辨率图像并记为  $I_{LR}^{bc}$ ,制作大量成对数据集  $(I_{HR}, I_{LR}^{bc})$  命名为  $D$ ,然后进行模型的训练。其损失函数如式(3)所示:

$$L^D(\theta) = E_{D \sim (I_{HR}, I_{LR}^{bc})} [\| I_{HR} - f_{\theta}(I_{LR}^{bc}) \|_1] \quad (3)$$

其中,  $f_{\theta}(\cdot)$  为超分辨率模型。退化后的低分辨率图像经过模型后输出高分辨率图像  $f(I_{LR}^{bc})$ ,此时将  $I_{HR}$  作为标签,并使用随机梯度下降(Stochastic Gradient Descent, SGD)进行优化,得到参数  $\theta_T^m$ ,进入元学习部分。元学习使用 MAML 算法,主要由元训练和元测试两部分构成,元训练的目的是使模型能够适应大量不同的任务。从任务分布  $P(T)$  中采样  $T_i$  用于元训练,在单个任务中,训练样本用来优化具有特定损失函数  $L_{T_i}$  的基础学习器,测试样本用来优化元学习器。对于一个新任务  $T_i$ ,参数  $\theta$  的更新规则为:

$$\theta_i = \theta - \alpha \nabla_{\theta} L_{T_i}^v(\theta) \quad (4)$$

其中,  $\alpha$  表示当前任务的学习率。训练过程的优化函数如式(5)所示:

$$\arg \min_{\theta} \sum_{T_i \sim P(T)} L_{T_i}^v(\theta_i) = \arg \min_{\theta} \sum_{T_i \sim P(T)} L_{T_i}^v(\theta - \alpha \nabla_{\theta} L_{T_i}^v(\theta)) \quad (5)$$

训练过程的优化策略使用随机梯度下降,其参数更新规则为:

$$\theta \leftarrow \theta - \beta \nabla_{\theta} \sum_{T_i \sim P(T)} L_{T_i}^v(\theta_i) \quad (6)$$

其中,  $\beta$  表示元学习率。元测试中,借助元学习器,模型能够快速适应新的任务  $T_{meta}$ ,适应过程实际上是对模型的进一步更新,最终得到外部训练的模型  $M_{meta}$ 。

大规模数据训练的主要贡献在两个方面。一方面,由于各超分辨率任务之间有相似的属性,因此可以隐式地学习到高分辨率图像的先验知识,模型仅通过一次训练,就会有很好的重建效果;另一方面,针对 MAML 训练不稳定的问题,经过有效训练的特征表达,可以增强元学习训练过程的稳定性。

### 2.2 内部训练

内部训练是将外部训练的参数  $\theta_M$  迁移到 ZSSR 中,可分为元训练阶段和元测试阶段。在元训练阶段,利用缺陷图像的自监督来训练具有相应模糊核的模型。将成对的  $(I_{HR}, I_{LR}^k)$  作为元训练的数据集,记为  $D_{meta}$ ,其中  $I_{HR}$  为缺陷图像,  $I_{LR}^k$  为退化后的图像。图像退化过程指由高分辨率图像变为低分辨率图像的过程。退化模型<sup>[13-14]</sup>如式(7)所示:

$$I_{LR}^k = (I_{HR} * k) \downarrow_s + n \quad (7)$$

其中,  $k$  表示模糊核,  $*$  表示卷积操作,  $\downarrow_s$  表示比例因子为  $s$  的样本抽取,  $n$  表示高斯白噪声。退化图像中含有多种模糊核信息,模糊核由各向同性和各向异性的高斯核组成,通过引入一个核分布  $p(k)$ ,每个核由协方差矩阵  $\Sigma$  决定,该协方差矩阵如式(8)所示。该矩阵由一个随机角  $\theta \sim U[0, \pi]$ 、两个随机特征值  $\lambda_1 \sim U[1, 2.5s]$  和  $\lambda_2 \sim U[1, \lambda_1]$  组成,其中  $s$  表示缩放因子。

$$\Sigma = \begin{bmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{bmatrix} \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{bmatrix} \begin{bmatrix} \cos(\theta) & \sin(\theta) \\ -\sin(\theta) & \cos(\theta) \end{bmatrix} \quad (8)$$

用数据集  $D_{meta}$  对模型进行二次更新,将数据集分为两个部分,  $D_{tr}$  用于训练,  $D_{te}$  用于测试。  $I_{LR}^k$  作为内部训练的输入,由  $I_{HR}$  对重建高分辨率图像进行监督,其模型结构基于 ZSSR,由 8 层卷积层组成,如图 4 所示。




图 4 ZSSR 结构图

Fig. 4 ZSSR network structure diagram

该 ZSSR 网络引入外部训练得到的模型参数,首先通过  $1 \times 1$  的卷积将维度由 3 提升到 64,然后经过 6 层卷积对特征进行进一步提取,此处设置卷积核个数均为 64,激活函数为 ReLU,最后使用  $1 \times 1$  的卷积降维。将上述过程的输出结果与  $I_{HR}$  进行对比,得到损失函数,并使用随机梯度下降进行模型优化。训练过程中,批标准化(Batch Normalization, BN)具有加快收敛、防止过拟合等优点,但在图像重建问题上,经批标准化后,提取的图像特征被归一化,图像空间受到破坏,对隐裂和断栅两种缺陷影响较大,因此本文将 BN 层删除,以达到提升图像重建效果、减少



### 3.3 在多种模糊核上的评估

本节在多种模糊核下进行实验,主要分为4种情况:严重混叠、各向同性高斯、各向异性高斯、各向同性高斯+双线性插值。下面给出具体实验方法。

(1)  $g_{0.2}^d$ :各向同性高斯模糊核,宽度参数为  $\lambda=0.2$ ,采用直接下采样方式。

(2)  $g_{1.0}^d$ :各向同性高斯模糊核,宽度参数为  $\lambda=1.0$ ,采用直接下采样方式。

(3)  $g_{ani}^d$ :各向异性高斯模糊核,宽度参数为  $\lambda_1=3.0, \lambda_2=1.0$ ,式(3)中的  $\theta=-2.0$ ,采用直接下采样方式。

(4)  $g_{1.5}^d$ :各向同性高斯模糊核,宽度参数为  $\lambda=1.5$ ,采用双三次插值下采样方式。

不同模糊核上的平均 PSNR/SSIM 结果如表 2 所列, MTSR 括号中的数字表示梯度更新次数,加深数字为最优结果。由于 RCAN 是在双三次插值下采样场景下进行训练的,区域之间存在差异并且缺乏灵活性,因此其性能较差。

表 2 基于不同模糊核、不同模型训练的比较

Table 2 Comparison of model training based on different blur kernel

Kernel	Dataset	Supervised			Unsupervised		
		Bicubic	RCAN	IKC	ZSSR	MTSR(1)	MTSR(10)
$g_{0.2}^d$	Set5	30.18/0.8758	28.40/0.8975	29.77/0.8736	<b>34.36/0.9348</b>	33.14/0.9377	33.75/0.9318
	BSD100	27.71/0.7927	25.75/0.7602	28.70/0.7688	<b>29.71/0.8466</b>	28.70/0.8358	29.34/0.8418
	ELdata	25.74/0.7845	21.67/0.7338	23.74/0.7684	<b>28.70/0.8799</b>	26.24/0.8268	26.67/0.8458
$g_{1.0}^d$	Set5	29.56/0.8455	29.56/0.8624	29.75/0.8896	34.96/0.9398	35.47/0.9348	<b>36.40/0.9454</b>
	BSD100	26.56/0.7843	25.89/0.7118	27.56/0.8158	30.74/0.8758	30.59/0.8675	<b>31.07/0.9438</b>
	ELdata	23.69/0.7508	24.41/0.7558	25.96/0.8547	27.72/0.8582	28.70/0.8658	<b>29.16/0.8858</b>
$g_{ani}^d$	Set5	27.24/0.8641	28.36/0.8631	28.74/0.8563	33.95/0.9308	34.35/0.9274	<b>34.79/0.9458</b>
	BSD100	25.89/0.6913	26.35/0.7059	26.72/0.7412	<b>29.77/0.8478</b>	28.81/0.8038	29.74/0.8458
	ELdata	23.48/0.6758	23.35/0.6948	23.68/0.7258	27.36/0.8354	26.70/0.8169	<b>27.75/0.8551</b>
$g_{1.5}^d$	Set5	30.58/0.8988	31.70/0.8958	33.71/0.9358	26.39/0.9568	35.19/0.9458	<b>36.66/0.9434</b>
	BSD100	27.70/0.7660	28.76/0.7958	30.98/0.8661	30.78/0.8758	29.03/0.8558	<b>31.73/0.8858</b>
	ELdata	24.71/0.7632	25.43/0.7458	29.77/0.8954	28.32/0.5364	28.70/0.8658	<b>29.85/0.8934</b>

对于加入混叠模型  $g_{0.2}^d$  的情况,由于训练条件与测试条件不一致,因此 RCAN 的结果比双三次插值下采样差。迭代内核校正 (Iterative Kernel Correction, IKC) [26] 进行了双三次插值采样训练,训练过程中并没有出现过混叠图像,因此其性能也严重下降。此外,初始点的随机性使其不能保证多次测试得到相同的结果。如表 2 所列,即使 MTSR(1) 方法只进行 1 次梯度更新,其效果也优于其他方法,并且  $\lambda=0.2$  更适用于 ZSSR,  $\lambda=1.0$  更适用于 MTSR(10); 通过比较 1 次迭代与 10 次迭代的平均 PSNR/SSIM 得出, MTSR 方法能够快速适应重建条件,具有更高的重建效率; 不同  $\lambda$  值的对比说明, MTSR 方法具有良好的泛化能力。

图 6 给出了对初始点和一次迭代后的结果进行可视化的结果图,上层是基于 MTSR 的实验,下层是在“双三次”退化上使用预训练网络进行的实验。

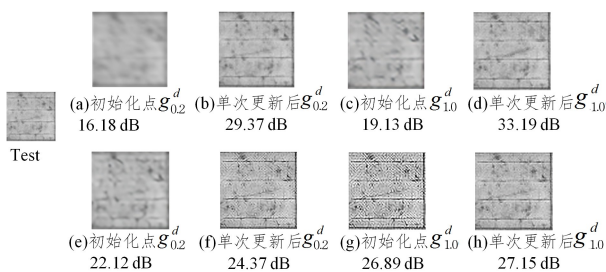


图 6 隐裂重建过程可视化

Fig. 6 Visualization of hidden crack reconstruction process

实验结果显示, MTSR 中参数  $\lambda$  与重建图像的质量成正比。经过预训练后的网络结构生成的图效果更加自然,

特征更加明显, 纹理也更加清晰, 甚至优于原图, 但一次迭代的效果改善不明显。

## 4 实验分析

### 4.1 PSNR 的比较

基于 EL 数据集进行实验, 得到基于不同超分辨率重建方法的训练结果, 如图 7 所示。可以看出, 基于元学习的超分辨率重建方法能够快速适应 EL 图像条件, 单次迭代后能保持最优的重建效果, 在 0 到 1 次迭代出现跳跃式提升, 说明即使初始数据与重建图像的相关性很差, 本文方法也能快速适应图像条件, 得到效果非常好的重建图像。




图 7 重建方法比较

Fig. 7 Comparisons of different methods

### 4.2 复杂度分析

对整个模型及时间复杂度进行多次比较, 结果如表 3 所列。实验在装有 NVIDIA GTX 1080Ti 图形处理器和 Intel Core i7 CPU 的计算机上运行。软件平台基于 Python3 和 Tensorflow 框架实现。

表 3 参数量及时间复杂度

Table 3 Number of parameters and time complexity

Methods	Parameters	Time/s
CARN	1 493 000	0.78
RCAN	133 430 000	2.76
ZSSR	265 000	249.15
MTSR(1)	195 000	0.27
MTSR(10)	195 000	0.56

通过对几种重建方法参数数量的比较得出,两种用于双三次插值的有监督前馈网络 CARN 和 RCAN 需要大量的参数,与 RCAN 相比,虽然 CARN 以轻量级网络被提出,但是与无监督网络相比,其参数量仍然巨大。另外,ZSSR 作为无监督学习,由于网络结构已经对图像数据进行一定程度的拟合,因此其参数量要少得多,但成百上千次迭代训练使其时间复杂度较高;通过对 ZSSR 中的卷积进行优化,MTSR 参数量降为 195 000,并且网络能够快速适应图像条件,大大降低了时间复杂度。

**结束语** 本文提出了一种快速、轻量级自监督超分辨率重建方法,利用外部和内部数据联合训练的策略,结合迁移学习将大量外部数据的公共特征、对不同任务的适应能力迁移到改进的 ZSSR 网络中,将外部公共特征与重建图像的内部信息相结合,使其快速适应新的特定图像条件,既保证了缺陷图像的重建质量,又提升了重建效率,且其效果优于其他重建方法。通过该方法对数据进行重建,能够在一定程度上缓解小样本问题。本文通过复杂性评估,从时间复杂度和参数量两个方面验证了该方法的有效性。采用缺陷重建的方法扩充数据集,不仅增加样本数量,使缺陷及周边纹理之间存在差异,而且还存在缺乏缺陷多样性的问题,未来我们将采用风格迁移来解决样本多样性问题。

## 参 考 文 献

- [1] JIANG J, LI M, ZHU M Q, et al. Crack detection of outdoor solar panel based on convolutional neural network[J]. Journal of Yangzhou University (Natural Science Edition), 2020, 23(1): 49-53.
- [2] CHEN F M, CHENG X Y, YAO Z F. Design of Solar Panel Defect Detection Model Based on Deep Learning[J]. Wireless Interconnection Technology, 2019, 16(23): 56-61.
- [3] GUO B S, ZHUANG J C, ZHANG Q, et al. Color difference detection of polysilicon wafers based on multi-component convolutional neural network[J]. China Mechanical Engineering, 2021, 23(18): 1-10.
- [4] SHOCHER A, COHEN N, IRANI M. Zero-Shot Super-Resolution Using Deep Internal Learning[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, 2018: 3118-3126.
- [5] MASTAN I D, RAMAN S. DCIL: Deep Contextual Internal Learning for Image Restoration and Image Retargeting[C]// 2020 IEEE Winter Conference on Applications of Computer Vision (WACV). Snowmass Village, CO, USA, 2020: 2355-2364.
- [6] JUNZHI Y. Zero-Shot Super Resolution for Satellite Remote Sensing Images[C]// 2019 IEEE International Conference on Signal, Information and Data Processing (ICSIDP). IEEE, 2019: 245-255.
- [7] FELUI-FABÁ J, FAN Y, YING L. Meta-learning pseudo-differential operators with deep neural networks[J]. Journal of Computational Physics, 2020, 5(23): 408-415.
- [8] PURI R. Few Shot Learning For Point Cloud Data Using Model Agnostic Meta Learning[J]. 2020 IEEE International Conference on Image Processing (ICIP), 2020, 13(5): 1906-1910.
- [9] DEMERTZIS K, ILIADIS L. GeoAI: A Model-Agnostic Meta-Ensemble Zero-Shot Learning Method for Hyperspectral Image Analysis and Classification[J]. Algorithms, 2020, 13(3): 61-68.
- [10] XU Z, CHEN X, TANG W, et al. Meta Weight Learning via Model-Agnostic Meta-Learning [J]. Neurocomputing, 2020, 432(7587): 342-356.
- [11] EIRIKUR A, RADU T. Ntire 2017 challenge on single image super-resolution: Dataset and study[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. 2017: 126-135.
- [12] LI Y M. Study on Bicubic Interpolation Algorithm for Images [D]. Lanzhou: Lanzhou University, 2020.
- [13] WANG J L, LIU L Q, ZHANG C M. Application of image processing in photovoltaic local shadow[J]. Journal of Solar Energy, 2020, 41(2): 284-289.
- [14] WU G, ZHAO L, WANG W, et al. PRED: A Parallel Network for Handling Multiple Degradations via Single Model in Single Image Super-Resolution[C]// 2019 IEEE International Conference on Image Processing (ICIP). Taipei, Taiwan, 2019: 5-10.
- [15] CHOLLET F. Xception: Deep Learning with Depthwise Separable Convolutions[C]// 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2017.
- [16] TAHIR S, JALAL A, KIM K. Wearable Inertial Sensors for Daily Activity Analysis Based on Adam Optimization and the Maximum Entropy Markov Model[J]. Entropy (Basel, Switzerland), 2020, 22(5): 1250-1258.
- [17] LAN R, SUN L, LIU Z, et al. Cascading and Enhanced Residual Networks for Accurate Single-Image Super-Resolution[J]. IEEE Transactions on Cybernetics, 2020, 43(99): 1-11.
- [18] MARCO B, ALINE R, CHRISTINE G, et al. Low-complexity single-image super-resolution based on nonnegative neighbor embedding[J]. BMVC, 2012, 54(9): 104-110.
- [19] DAVID M, CHARLESS F, DORON T, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics[J]. Computer Vision, 2001, 19(6): 416-423.
- [20] MEHTA J H. Relation between Entropy and Peak Signal to Noise Ratio in Prediction Error Expansion Considering Region of Interest [J]. International Conference for Convergence in Technology (I2CT), 2019, 69(9): 1-4.
- [21] ELACHKAR I, OUZIF H, LABRIJI H. Structural Similarity

- Measure of Users Profiles Based on A Weighted Bipartite Graphs[J]. ISPRS International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2020, 66(5):1-9.
- [22] LAN R, SUN L, LIU Z, et al. Cascading and Enhanced Residual Networks for Accurate Single-Image Super-Resolution[J]. IEEE Transactions on Cybernetics, 2020, 66(99):146-155.
- [23] QI Y, GU J, LI W, et al. Pulmonary nodule image super-resolution using multi-scale deep residual channel attention network with joint optimization [J]. The Journal of Supercomputing, 2019, 76(3):1508-1515.
- [24] DENIZ K, HAKAN A. A Novel Short-Term Photovoltaic Power Forecasting Approach based on Deep Convolutional Neural Network[J]. International Journal of Green Energy, 2021, 18(5):34-39.
- [25] LEE K, LEE E, CHOI B, et al. Automatic Pharyngeal Phase Recognition in Untrimmed Videofluoroscopic Swallowing Study Using Transfer Learning with Deep Convolutional Neural Networks[J]. Diagnostics, 2021, 11(2):622-630.
- [26] GU J, LU H, ZUO W, et al. Blind Super-Resolution with Iterative Kernel Correction [C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2019:1245-1250.



**ZHOU Ying**, born in 1971, Ph.D, associate professor. Her main research interests include computer vision, image processing and deep learning.



**ZHANG Yan**, born in 1974, Ph.D, professor, Ph.D supervisor. Her main research interests include intelligent rehabilitation device and control theory.

(责任编辑:柯颖)