

基于轻量级密集残差网络的输电线路绝缘子红外图像的超分辨率重建

吴田^{1,2}, 杨威^{1,2}, 陶雄俊³, 王申华⁴, 黎鹏^{1,2}, 普子恒^{1,2}, 方春华^{1,2}

(1. 三峡大学电气与新能源学院, 湖北宜昌 443002; 2. 三峡大学湖北省输电线路工程技术研究中心, 湖北宜昌 443002; 3. 中国南方电网有限责任公司超高压输电公司昆明局, 昆明 650000; 4. 国网浙江省电力有限公司武义县供电公司, 浙江金华 321200)

摘要: 红外成像是检测输电线路绝缘子发热缺陷的一种有效方法, 受采集设备和拍摄距离的影响, 其分辨率较低, 图像中绝缘子目标小, 大量数据难以处理。针对红外图像分辨率低的问题, 文章提出了一种基于轻量级密集残差网络 (lightweight residual in residual dense block, LRRDB) 的图像超分辨率重建算法 (I-SRGAN), 设计一种轻量级的密集残差网络, 加深网络的深度以提取到更深层次的特征信息, 通过深度可分离卷积减少网络参数量; 为了克服网络深度过深存在的过拟合和“梯度爆炸”等问题, 采用 Wasserstein 梯度惩罚保证网络训练的稳定性; 并结合自注意力机制 (self-attention, SA) 自适应调节特征信息的权重, 提升网络对重要特征的关注。通过对±800 kV 输电线路绝缘子红外图像进行超分辨率重建试验, 结果表明: I-SRGAN 在峰值信噪比 (peak signal-to-noise ratio, PSNR) 上比 SRGAN (super resolution using a generative adversarial network) 平均值高 3.57%; 在结构相似度 (structural similarity index measure, SSIM) 上比双三次插值 (BiCubic) 方法提高 3.90%, 比 SRCNN (super-resolution convolutional neural network) 提高 2.68%, 比 SRGAN 提高 1.41%, 轻量级的加入也使重建时间大大减少, 可为输电线路绝缘子红外图像的超分辨率重建提供参考。

关键词: 绝缘子; 超分辨率重建; 轻量级密集残差块; 注意力机制

Super-resolution Reconstruction of Infrared Image of Transmission Line Insulator Based on Lightweight Residual in Residual Dense Net

WU Tian^{1,2}, YANG Wei^{1,2}, TAO Xiongjun³, WANG Shenhua⁴, LI Peng^{1,2}, PU Ziheng^{1,2}, FANG Chunhua^{1,2}

(1. College of Electrical Engineering & New Energy, China Three Gorges University, Hubei Yichang 443002, China; 2. Hubei Provincial Engineering Technology Research Center for Power Transmission Line, China Three Gorges University, Hubei Yichang 443002, China; 3. Kunming Bureau of EHV Power Transmission Company of China Southern Power Grid Co. Ltd, Kunming 650000, China; 4. Wuyi County Power Supply Company of State Grid Zhejiang Electric Power Co., Ltd., Zhejiang Jinhua 321200, China)

Abstract: Infrared imaging is an effective method to detect thermal defects of transmission line insulators. Due to the influence of acquisition equipment and shooting distance, its resolution is low, the insulator target in the image is small, and a large amount of data is difficult to process. To solve the problem of low infrared image resolution, this paper proposes an image super resolution reconstruction algorithm (I-SRGAN) based on Lightweight residual in residual dense block (LRRDB). The depth of the network is deepened to extract deeper feature information, and the number of network parameters is reduced by depth-separable convolution. In order to overcome the problems of overfitting and gradient explosion, Wasserstein gradient penalty is used to ensure the stability of network training. Combined with the self-attention (SA) mechanism, the weight of feature information is adjusted adaptively to enhance the network's attention to important features. Through the super-resolution reconstruction test on the infrared image of insulator of ±800kV transmission line, the results show that: The peak signal-to-noise ratio (PSNR) of I-SRGAN is 3.57% higher than the average value of super resolution using a generative adversarial network (SRGAN). The Structural Similarity Index Measure (SSIM) is 3.90% higher than that of BiCubic. Compared with SRCNN (super-resolution convolutional neural network), it is 2.68% higher than SRGAN (1.41% higher than SRGAN). The lightweight addition also greatly reduces the reconstruction time, which can provide a reference for the super-resolution reconstruction of the infrared image of the transmission line insulator.

Key words: insulator; super resolution reconstruction; lightweight residual in residual dense block; attention mechanism

0 引言

绝缘子作为保证输电线路安全运行的关键组成部分, 在长期挂网运行后, 难免会有所缺陷, 及时

发现绝缘子的缺陷尤为重要^[1-6]。红外图像是检测输电线路绝缘子低零值等发热类缺陷的一种有效方法, 但由于无人机搭载红外设备拍摄距离的影响, 所获得的红外图像的分辨率较低, 且输电线路环境

基金项目: 国家自然科学基金资助项目(51807110)。

Project Supported by National Natural Science Foundation of China(51807110).

复杂导致红外图像的背景复杂,在进行缺陷识别时会存在分辨率低和识别难等问题^[7-10]。红外图像的分辨率主要由红外成像设备中的红外探测器决定,然而从硬件上改进红外探测器的难度较大,所以亟需从软件上着手,对输电线路绝缘子红外图像的分辨率进行提升。

随着计算机技术的快速发展,图像超分辨率重建技术应运而生,并在医学影像分析、遥感成像、视频处理等领域中广泛应用^[11-13];按照研究方法可分为基于插值、基于重建约束超、以及基于学习的超分辨率重建算法^[14-17]。基于学习的超分辨率重建方法重建效果较好,且在图像重建领域应用广泛。Dong 团队提出的 SRCNN^[18]和 FSRCNN^[19](feature super-resolution convolutional neural network)首次将神经网络运用到超分辨率重建中,获得了较好的重建效果。Kim^[20]等人提出的 VDCN(very deep convolution networks)算法首次将残差学习和梯度裁剪引入图像超分辨率中,使用自适应梯度裁剪来解决网络加深时训练困难和性能下降的问题,证明了网络结构越深重建效果越好。Ledig 等人^[21]提出的 SRGAN 将超分辨率重建与生成对抗网络相结合,提出以内容损失、感知损失和对抗损失作为损失函数,使重建的图像在人眼感知上更接近高分辨率图像。Zhao 等人^[22]提出边缘注意力生成对抗网络(EA-GAN),将边缘注意力加入 GAN 中,通过对图像特征通道的边缘强度对通道重新分配权重,对变电站设备红外图像进行图像重建,取得了较好的效果,但其数据样本较少,且拍摄图像距离较近。刘志坚^[23]等人也对电力设备红外图像进行超分辨率重建,将残差网络融合到 GAN 中,并使用 SN 归一化优化判别器,最终在 PSNR 和 SSIM 上均有所提升,但其数据集仅为 400 张红外图像,且重建后的图像与原图像提升不太明显。韩龙^[24]等人也对电力设备

红外图像进行了超分辨率重建,自己拍摄红外图像的数据集样本足够,但其样本只有校园内的电气设备,拍摄距离近,角度容易调整。

文章针对 ± 800 kV 特高压直流输电线路绝缘子红外图像拍摄距离远,分辨率低,绝缘子目标在图像中占比小,不利于进行在线监测和实时检测等问题,提出了一种基于轻量级密集残差网络的输电线路绝缘子红外图像的超分辨率重建方法 I-SRGAN。首先,使用轻量级密集残差块,增加网络深度和特征表示能力,提取到更丰富的特征信息;其次,加入 Wasserstein 梯度惩罚模块,在加深网络深度的同时保证训练的稳定性,提高模型的鲁棒性,降低网络崩溃的风险;然后,嵌入 SA 模块,在提取图像特征信息时将更多权重分配给所需信息。最后,将 I-SRGAN 重建的图像与 BiCubic、SRCNN、SRGAN 对比,通过试验验证了 I-SRGAN 在客观评价指标和人的主观视觉上均优于其他算法,重建后的绝缘子图像在整体和边缘部分均有显著提升。

1 文中算法模型

1.1 轻量级残差密集生成对抗网络

文中绝缘子红外图像超分辨率模型以 SRGAN 为框架,提出了一种基于轻量级残差密集网络的超分辨率重建网络,该网络由生成器 G 和判别器 D 两个网络模块组成,其整体结构网络图见图 1。G 包含上采样、LRRDB、SA 模块进行特征提取和权重的自适应分配;与原始 SRGAN 的简单残差模块相比,LRRDB 中包含更多的卷积层和激活函数层,并用跳跃连接保证特征信息的高效利用、去除冗余的批量归一化层(batch normalization, BN)层,减少了内存与计算量的消耗。加入 SA 模块,使生成器提取图像特征时,自适应的调整权重参数,将更大的权重值分配给重要特征信息,对绝缘子的特征信

息加强重建，弱化其它部件和背景的重建效果。在判别器 D 中加入 Wasserstein 梯度惩罚模块^[25]，该模块能解决 GAN 训练不稳定的问题，无需平衡生成器和判别器的训练程度；基本能解决模型坍塌的问题，即网络深度和复杂度不会对网络的训练造成影响；减少模型的变异，提高模型的鲁棒性。

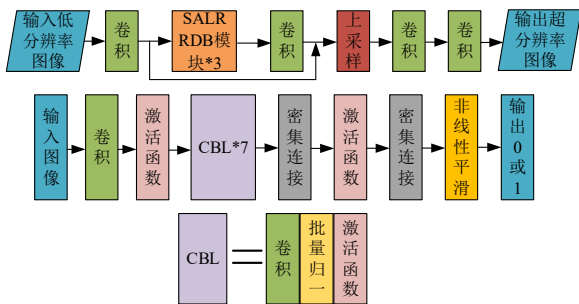


图 1 轻量级残差密集生成对抗网络结构图

Fig. 1 LRRDB generative adversarial network structure

1.2 SRGAN 算法

SRGAN 是基于 GAN^[26]的超分辨率重建方法，其重建流程见图 2。该方法利用残差块(residual block, RB)和上采样对低分辨率图像(low resolution, LR)进行特征提取，然后将提取到的特征输入生成器中进行学习以生成超分辨率(super resolution, SR)图像，并将 SR 图像送入判别器；判别器将 SR 图像与原始高分辨率图像(high resolution, HR)进行判别，将其输出结果送入生成器中，生成器则根据判别器的输出进行更新，然后重复学习。当判别器无法准确判断输入图像是 SR 图像还是 HR 图像时，生成器达到最优训练效果，此时，生成的 SR 图像效果最好。




图 2 SRGAN 重建流程图

Fig. 2 Reconstruction flow chart of SRGAN

SRGAN 在红外图像重建上存在如下不足：重建的 RGB 图像效果比较接近原图，但在红外图像上的效果不太明显；网络深度较浅、特征信息提取不足；在进行特征信息处理时，将权重平均分配，导致图像中无用和有用的特征信息被同样放大，不利于后期对图像进行检测或识别。针对上述问题，文中对 SRGAN 进行改进，使其能提取更丰富的深层特征信息，并自适应分配特征信息的权重，同时保证训练的稳定性，进而提升了其在红外图像超分辨率重建上的效果。

1.3 轻量级残差网络

由文[20]知残差块只学习 LR 和 HR 之间的高频残差部分，减少了提取图像特征的数量，加快了训练速度并减小计算量且证明了网络结构越深，重建效果越好。原始 SRGAN 中 RB 仅包含两层卷积和激活函数，在网络深度上比较浅，难以提取到更深层的特征信息。因此将生成器部分的 RB 替换为 RRDB(residual in residual dense block)见图 3，该网络采用了两层残差网络，其主干部分由 3 个密集残差块构成，极大地增加了生成器网络的深度，能提取到更深层的特征信息，并通过跳跃连接确保特征信息得到充分利用。每个 RRDB 中包含 5 个卷积层和 4 个非线性激活层，增加了网络的非线性变换深度，从而可捕获到更复杂的特征信息。

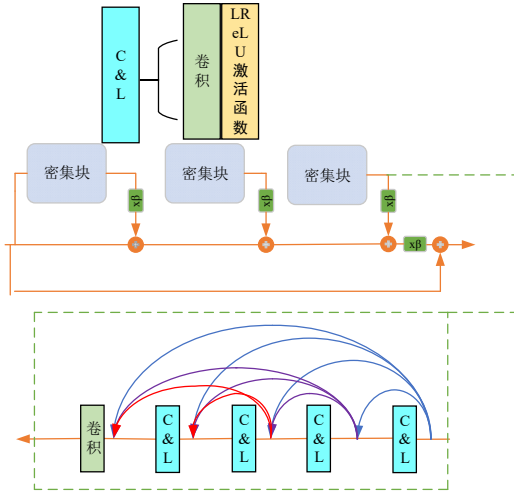


图3 RRDB网络结构

Fig. 3 RRDB Network structure

RRDB 虽然在网络深度上有了很大的提升,但由于其网络结构过于复杂,严重影响了网络的训练速度。因此,本文在其基础上设计了一种轻量级密集残差网络(lightweight residual in residual dense block, LRRDB),将 RRDB 中的普通卷积网络替换为深度可分离卷积^[27](depthwise separable convolution, DSC),见图 4。DSC 将卷积操作分为逐通道卷积和逐点卷积两步,从而分别对图像的空间和通道特征进行处理。在逐通道卷积操作中,特征图的每个通道被看成相互独立,卷积操作也只在单通道进行。逐通道卷积完成后,卷积后生成的特征图的通道数与原始特征图相同,不会对其扩充,因此各通道之间的信息相对独立,没有交融。为了克服以上问题,在特征图通道上进行逐点卷积,在每个通道上使用 1×1 的标准卷积,使不同通道之间的特征信息相互交融、共享,组合出新的特征图。逐点卷积操作能增强特征图相互之间的信息交换融合,同时实现对特征图的升维和降维。这种卷积操作实现了空间相关性和通道相关性的分离,从而在不影响所获取的特征信息的同时,减轻网络的复杂程度和冗余度,加快了训练速度并节省了存储空间和计算资源。




图4 深度可分离卷积特征处理过程图

Fig. 4 DSC feature processing

1.4 自注意力机制

人类可以在复杂的自然场景中有效地找到显著的区域,受此观察启发,注意力机制应运而生并被引入计算机视觉中,该机制可视为基于输入图像特征的动态权重调整过程^[28]。自注意力机制^[29]是由 Google 所提出的将单个序列的不同位置关联起来以计算序列表示的点积型注意力机制,点积型注意力相对于加性注意力而言,在实践中速度更快且更节省空间。嵌入自注意力机制,使生成器提取图像特征时,能对图像建立长距离、多层次的特征依赖关系,重建图像的视觉效果更加逼真;判别器也能更好地对全局图像进行判断。该机制可表示为

$$F(Q,K,V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (1)$$

式(1)中: Q 是查询; K 是键; V 是值; d 是 K 的维度; softmax 是归一化指数函数。

式(1)中 Q 的作用是去匹配每一个 K , V 则是被提取的特征信息。 Q 和 K 的匹配过程实际上是计算两者的相关性,相关性越大,则对应的 V 的权重就越大。式(1)可以表示为图 5,将输入的 Q 和 K^T 进行点积,然后除以 $\sqrt{d_k}$,再应用 softmax 函数对其值归一化从而得到 V 的权重系数。

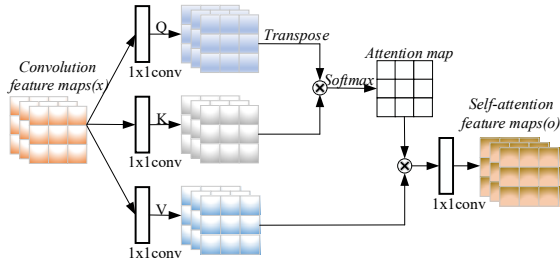


图 5 比例点积注意力

Fig. 5 Scaled Dot-Product Attention

1.5 损失函数

损失函数是约束生成对抗网络中生成器和判别器训练过程中用于评价超分辨率重建图像和原始高分辨率图像的差距的函数。在 SRCNN 等算法中，使用 MSE (mean square error) 作为损失函数能够带来较大 $PSNR$ ，但重建图像会丢失高频细节部分， MSE 损失函数为

$$L_{MSE} = \frac{1}{r^2WH} \sum_{x=1}^{rW} \sum_{y=1}^{rH} (I_{x,y}^{SR} - I_{x,y}^{HR})^2 \quad (2)$$

式(2)中： r 是放大倍数； W 和 H 分别是图像的宽和高； SR 是重建后的超分辨率图像； HR 是原始高分辨率图像。

为了克服 MSE 损失函数的不足，文中引入文[21]中提出的损失函数 L ，该函数由 3 部分组成，其表达式为

$$L = L_{per} + \lambda L_{adv} + \mu L_{con} \quad (3)$$

式(3)中： L_{con} 是内容损失，使用 MSE 损失函数； L_{per} 是感知损失； L_{adv} 是对抗损失； λ 和 μ 为权重系数。

感知损失 L_{per} 由预先训练好的 VGG19 网络提供，其计算式为

$$L_{per} = \frac{1}{W_{ij}H_{ij}} \sum_{x=1}^{W_{ij}} \sum_{y=1}^{H_{ij}} (\phi_{ij}(I^{HR})_{x,y} - \phi_{ij}(G(I^{LR}))_{x,y})^2 \quad (4)$$

式(4)中： W_{ij} 和 H_{ij} 分别是判别模块中第 i 个最大池化层之前通过 j 次卷积获得的特征图的宽度和高度； x 和 y 则分别是当前某个像素点在特征图中

的横坐标和纵坐标； ϕ_{ij} 是判别模块中第 i 个最大池化层之前通过 j 次卷积获得的特征图； I^{HR} 是高分辨率图像； I^{SR} 是低分辨率图像； G 为生成器网络。

式(3)中对抗损失 L_{adv} 采用的则是二分类交叉熵损失 BCEloss 函数，在生成对抗网络的训练中，鉴别器 D 的输出为一个二分类 0 或 1，采用一定权重的 BCEloss 来对整体损失函数约束，其计算式为

$$L_{adv} = -(D \log(D(G(z))) + (1 - D) \log(1 - D(G(z)))) \quad (5)$$

式(5)中： D 表示真实数据的标签信息； $D(G(z))$ 则表示由生成器生成的数据信息。

2 算例分析

2.1 红外图像数据采集

文中所用数据集为无人机携带红外设备对某 ± 800 kV 输电线路绝缘子拍摄所得。所用无人机为大疆禅思 H20T，热成像传感器为非制冷氧化钒微测热辐射计，其参数见表 1，拍摄绝缘子选择铁红调色盘、区域测温为最优。

表 1 大疆禅思 H20T 参数

Table 1 DJI Zen H20T parameters

参数	数据
焦距	5 m 及以上
数字变焦	1×、2×、4×、8×
图片分辨率	640×512
图片格式	R-JPEG
测温范围/°C	-40~150/-40~550
测温方式	点测温、区域测温
调色盘	白热/熔岩/铁红/热铁/医疗等

在拍摄时需要多人配合操作，一人用望远镜观察无人机整体飞行位置和距离绝缘子位置，一人操作无人机调整拍摄距离和焦距，以便拍摄更符合巡检规定的图像。拍摄时环境温度不低于 0 °C，风速不大于 5 m/s，湿度 RH 不大于 85% 。

对于 500 kV 及以上电压等级线路使用的长串复合绝缘子，为严格避免伞裙遮挡，意味着必须分开拍摄多张照片，此时应相对绝缘子方向平移无人机，保证拍摄距离和角度不变，操作难度很大，而

出于相对温升分析严谨的考虑又应当把整串绝缘子拍摄在一张照片中。

经拍摄，文中获取 3 000 张绝缘子红外图像，原始像素为 640×512，在进行试验之前，对其进行灰度变换，见图 6。再对灰度化之后的图像进行翻转、旋转，得到 12 000 张图像，以此保证训练样本的多样性。按照 8:2 的比列将其分为训练集和测试集进行试验。




图 6 数据集准备图样

Fig. 6 Data set preparation diagram

2.2 试验设置与评价指标

本试验所用算法的代码运行环境见表 2。

表 2 运行环境及参数版本

Table 2 Version and parameters of the running environment

参数	配置及版本
CPU	AMD EPYC 9754
GPU	NVIDIA Ge Force RTX 3090
运行内存	Kingston DDR4 64GB
操作系统	Windows 10, 64 位
CUDA 版本	CUDA 11.3
深度学习框架	PyTorch
图像处理库	Pytorch 1.10
Python 环境	Anaconda 2020.07
优化器	RMSprop
批次大小	16
迭代次数(Epoch)	500
学习率(Learn rate)	0.05
权值衰减系数	0.001

实验中选择传统的重建算法 BiCubic 双三次插

值和深度学习中的 SRCNN、SRGAN 算法进行对比。以 PSNR 和 SSIM 作为评价指标,对重建结果进行分析。PSNR 是用来评价图像接近度的一种客观评价指标,其取值范围一般在 20~40,其值越大表示图像在像素级上的质量越好,其公式为

$$PSNR = 10 \log_{10} \left(\frac{(2^n - 1)^2}{MSE} \right) \quad (6)$$

式(6)中, MSE 是均方差损失函数。

但 PSNR 并不能很好地反映感知差异如图像的高频纹理细节,文中采用 SSIM 分别从亮度、对比度和结构三方面度量图像相似性,其取值范围为 0~1,值越大,表示相似度越高,其公式为

$$SSIM(X, Y) = \frac{(2\mu_X\mu_Y + C_1)(2\sigma_{XY} + C_2)}{(\mu_X^2 + \mu_Y^2 + C_1)(\sigma_X^2 + \sigma_Y^2 + C_2)} \quad (7)$$

式(7)中: μ_X 和 μ_Y 分别是低分辨率图像 X 和高分辨率图像 Y 的均值; σ_X 和 σ_Y 分别是 X 和 Y 的方差; σ_{XY} 是 X 和 Y 的协方差; C_1 和 C_2 是常数。

2.3 训练结果分析

传统的 BiCubic 双三次插值方法不存在训练过程,因此文中主要对比了 SRCNN、SRGAN 以及 I-SRGAN,其在每次迭代过程中的图像训练集对应的 PSNR 和 SSIM 的平均值见图 7、8。

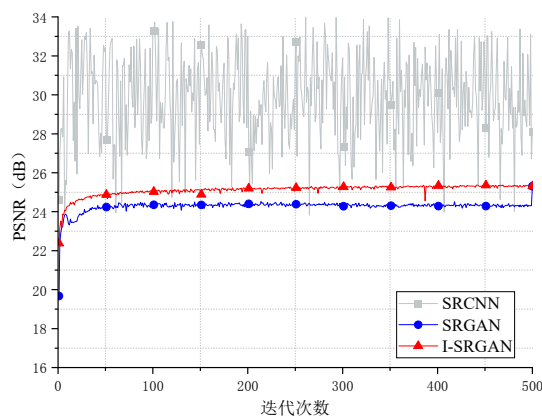


图 7 训练集 PSNR 迭代曲线

Fig. 7 PSNR iteration curve of training set




图 8 训练集 SSIM 迭代曲线

Fig. 8 SSIM iteration curve of training set

因 I-SRGAN 增加了网络的深度与复杂程度,在训练的稳定性上比 SRCNN 要稳定,且在训练稳定后,数值上优于 SRGAN,见图 7、8。如文中 2.2 节中所述, MSE 损失函数能带来更大 PSNR 值,因此 SRCNN 算法的 PSNR 在峰值比 SRGAN 与 I-SRGAN 都更大,但其非常不稳定,而且在人眼的主观感受上并不能很好地反映图像的质量高低。在 SSIM 上, I-SRGAN 对比 SRCNN 更加稳定且上升趋势明显,对比 SRGAN 在数值上有显著提升。在训练集的 SSIM 指标上,第 150~350 个迭代过程中 I-SRGAN 的数值略有波动,分析其原因由于加入的残差网络层次多,导致网络整体层次较深,在训练

过程中会有一点不稳定,但经过第 350 此迭代之后,可以看见 SSIM 数值明显稳定下来,体现出加入 Wasserstein 的作用,使网络保持稳定的训练,第 350 次迭代之后, SSIM 数值稳定,且其值较 SRGAN 的数值有明显提升。

将训练集所得 PSNR 和 SSIM 计算得出平均值见表 3。在训练集的 SSIM 平均值上, I-SRGAN 对比 SRCNN 提高了 4.25%,对比 SRGAN 提高了 16.76%;对 SRGAN 的改进增强了网络的学习能力,在训练效果上显著提升。

表 3 训练过程 PSNR 和 SSIM 的平均值

Table 3 The average value of PSNR and SSIM in the training process

参数	SRCNN	SRGAN	I-SRGAN
PSNR	29.974 55	24.276 12	25.121 36
SSIM	0.795 53	0.710 27	0.829 34

2.4 测试结果分析

文中在测试集中随机选取 4 张图像作为展示,见图 9, HR 为原始红外图像对应的灰度图,其余 5 张为 HR 中方框内绝缘子放大图像,依次为 HR 对应放大图像 Ground Truth、BiCubic 双三次插值算法、SRCNN、SRGAN、I-SRGAN 算法。测试集中的 PSNR 和 SSIM 值均是对整体图像进行评价。



吴田

作者简介:

吴田(1983),男,博士,高级工程师,研究生导师,研究方向为电网智能运检和带电作业等, E-mail: wutian_08@163.com

杨威(1999),男,通信作者,硕士研究生,研究方向为电网智能运检、图像处理, E-mail:1241573196@qq.com.

(a) 图 A



吴田

作者简介:

吴田 (1983), 男, 博士, 高级工程师, 研究生导师, 研究方向为电网智能运检和带电作业等, E-mail: wutian_08@163.com

杨威 (1999), 男, 通信作者, 硕士研究生, 研究方向为电网智能运检、图像处理, E-mail:1241573196@qq.com。

(b) 图 B



吴田

作者简介:

吴田 (1983), 男, 博士, 高级工程师, 研究生导师, 研究方向为电网智能运检和带电作业等, E-mail: wutian_08@163.com

杨威 (1999), 男, 通信作者, 硕士研究生, 研究方向为电网智能运检、图像处理, E-mail:1241573196@qq.com。

(c) 图 C



吴田

作者简介:

吴田 (1983), 男, 博士, 高级工程师, 研究生导师, 研究方向为电网智能运检和带电作业等, E-mail: wutian_08@163.com

杨威 (1999), 男, 通信作者, 硕士研究生, 研究方向为电网智能运检、图像处理, E-mail:1241573196@qq.com。

(d) 图 D

图 9 不同拍摄角度下绝缘子重建对比

Fig. 9 Comparison of insulator reconstruction at different shooting angles

如图 9 所示, 将方框中绝缘子放大之后, 观察 Ground Truth 图像, 难以辨识绝缘子, 该图像模糊、锯齿明显, 且亮度较低。I-SRGAN 对比 BiCubic 和 SRCNN, 图像整体上绝缘子结构更清晰、对比度更

高, 在绝缘子边缘部分锯齿更少, 重建效果明显提升; 对比 SRGAN, 将图像再次放大后, 绝缘子边缘更加清晰, 锯齿几乎消除, 而且图像的整体亮度优于 SRGAN; 在绝缘子灰度图像重建上的效果较

其他 3 种方法均有较大提升。

将测试集中选取的图像进行 *PSNR* 和 *SSIM* 指标计算, 其结果见表 4、5。由错误!未找到引用源。可得, I-SRGAN 使用了对抗损失、感知损失和 *MSE* 损失函数, 在 *PSNR* 的平均数值比 SRCNN 小 17.79%, 但比 BiCubic 提高了 18.86%; 比 SRGAN 提高了 3.57%, 即在使用相同损失函数的基础上, 重建效果优于 SRGAN。

表 4 不同算法放大 4 倍图像重建 *PSNR* 比较

Table 4 *PSNR* comparison of magnified 4 times reconstruction result

图号	BiCubic	SRCNN	SRGAN	I-SRGAN
A	21.598 80	31.481 19	23.562 69	24.619 02
B	20.918 29	26.453 96	24.082 90	24.654 92
C	20.004 24	28.647 56	24.322 74	25.352 23
D	21.145 05	30.553 83	24.050 15	24.817 52

表 5 不同算法放大 4 倍图像重建 *SSIM* 比较

Table 5 *SSIM* comparison of magnified 4 times reconstruction result

图号	BiCubic	SRCNN	SRGAN	I-SRGAN
A	0.865 75	0.877 51	0.884 18	0.896 33
B	0.866 34	0.876 58	0.885 83	0.898 00
C	0.863 97	0.875 81	0.879 65	0.896 95
D	0.859 46	0.877 87	0.890 15	0.898 97

由表 5 可得, I-SRGAN 在 4 张测试图像上, 对比于其他 3 种算法的 *SSIM* 值均为最高, 且平均值比 BiCubic 方法提高 3.90%, 比 SRCNN 提高 2.68%, 比 SRGAN 提高 1.41%; 重建的图像在结构相似性上与原始图像最为相似, 绝缘子结构重建在整体和边缘轮廓的效果均为最优。

如文中 1.5 小节所述, SRCNN 仅使用 *MSE* 损失函数, 因此能获得较大的 *PSNR*, 而 I-SRGAN 所改进的损失函数虽然不能获取较大的 *PSNR*, 但在 *SSIM* 上明显优于 SRCNN。较大的 *PSNR* 也并不能代表所生成的图像质量就比较好, 而 *SSIM* 的数值则能更好地反映出人眼对图像清晰度的感知。

由于文中算法在网络模型上有所加深, 在此对其处理效率进行检验, 判断改进之后是否会对图像处理效率影响较大。在处理完全相同的数据集且算法的学习率和批次大小都设置相同的情况下, 效率与时间成反比, 即时间越长效率越低。由于训练集庞大, 训练时间长, 在此不讨论效率问题。现将测试集中四组图像进行检验, 分别将 SRCNN、SRGAN、I-SRGAN 在单张 RTX 3060 和单张 RTX 3090 的显卡上进行检验, 得到表 6 数据。第一组数据为采用 RTX 3060 显卡的重建时间, 第二组数据为采用 RTX 3090 显卡的重建时间。

表 6 不同算法采用 RTX 3060/RTX 3090 放大 4 倍图像的重建时间比较

Table 6 Time comparison of magnified 4 times reconstruction result reconstructed by RTX3060/RTX3090

图号	SRCNN/s	SRGAN/s	I-SRGAN/s
A	4.71/7.21	11.64/10.28	9.35/8.33
B	4.51/7.20	10.90/10.30	9.42/8.51
C	4.62/7.17	11.07/10.40	9.33/8.42
D	4.57/7.67	10.86/10.26	9.29/8.39

首先比较 3 种不同算法在采用 RTX 显卡的重建时间, 随着网络结构的加深, 重建的时间明显增加, 从 SRCNN 到 SRGAN 增长较大, 而从 SRGAN 到 I-SRGAN 时间减少, 即表明本文所提轻量级密集残差网络起到效果, 在重建上减少时间; 再看 RTX 3090 显卡的重建时间, I-SRGAN 在 SRGAN 的基础上也有所减少, 在实际在线重建中有较大优势; 其次比较两组数据在 RTX 3090 显卡上的重建时间和 RTX 3060 显卡的重建时间, SRGAN 和 I-SRGAN 都有下降, 而 SRCNN 却有所增加, 其原因可能是主要取决于算法的适用性和显卡的性能, 而且同一张图像的处理时间在每次重建时也会略有差异, 本文对图像 A 用 I-SRGAN 算法和 RTX3090 显卡重建 50 次, 其中最慢的一次消耗 8.48 s, 最快

的一次是 8.26 s，最快与最慢之间相差在 0.2 s 左右，最大时间差占 50 次平均重建时间的 2.2%。图像处理效率的问题除了与网络结构的复杂度相关，还取决于所用设备的运算性能。

2.5 消融试验

为了验证文中所提 RRDB 和 Wasserstein 对网络训练的提升效果，在此进行消融实验。首先只对原始 SRGAN 的生成器进行改进，将 RB 替换为 RRDB 网络，进行训练；然后再加入 Wasserstein 梯度惩罚模块和 SA，来保证网络训练的稳定性，进行第二次训练。因为 SA 是对特征信息的权重进行自适应调整，并不会影响训练过程的评价指标，因此不单独训练。训练过程的 PSNR 和 SSIM 分别见图 10、11。

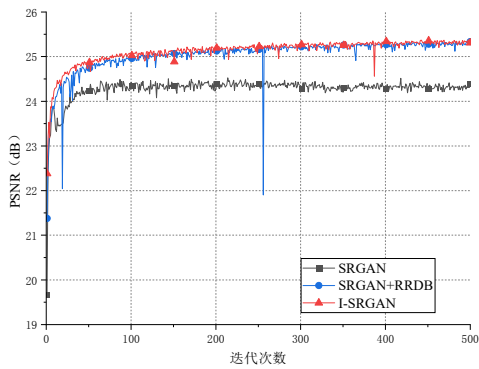


图 10 消融实验训练过程 PSNR 图

Fig. 10 PSNR diagram of ablation experimental training process

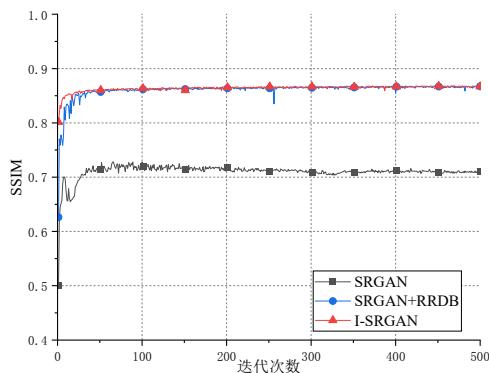


图 11 消融实验训练过程 SSIM 图

Fig.11 SSIM diagram of ablation experimental training process

从图 10 中可以看出在加入 RRDB 后，PSNR 有明显提升，但其波动性比较大，训练不够稳定，加入 Wasserstein 后可以看出网络训练明显稳定下来。如图 10 所示，改进后的网络训练得到的 SSIM 值明显更优，且 I-SRGAN 的起始值是最高的，对比另外两条曲线也更早进入收敛阶段。

3 结语

文中所提方法，通过对原始 SRGAN 进行改进，提出一种轻量级密集残差块，不仅加深了网络深度、扩大网络容量且能提取更丰富的局部特征，而且减少计算量，加快网络重建速度；嵌入自注意力机制，将更高权重分配给图像中的有用特征信息；添加 Wasserstein 梯度惩罚，保证了训练的稳定性。

通过试验证明，I-SRGAN 在 800 kV 输电线路绝缘子红外图像的重建上，在测试集平均值上，PSNR 较 BiCubic 提高了 18.86%，较 SRGAN 提高了 3.57%；SSIM 比 BiCubic 方法提高 3.90%，比 SRCNN 提高 2.68%，比 SRGAN 提高 1.41%。且本文重建图像在主观视觉上均有更好的效果，如图像的结构相似性、边缘清晰度、整体亮度和平滑度都更优于其它算法，在重建时间上也有较大优势，对于后期处理大量红外图像数据、开展绝缘子缺陷检测等工作具有实际工程价值。

参考文献：

- [1] 刘 辉，张 洋，李子岳，等. 复合绝缘子内部缺陷微波致热检测方法[J]. 高压电器，2023，59(3): 179-188. LIU Hui, ZHANG Yang, LI Ziyue, et al. Internal defect detection method of composite insulator based on microwave heating[J]. High Voltage Apparatus, 2023, 59(3): 179-188.
- [2] 王道累，孙嘉珺，张天宇，等. 基于改进生成对抗网络的玻璃绝缘子自爆缺陷检测方法[J]. 高电压技术，2022，48(3): 1096-1103. WANG Daolei, SUN Jiajun, ZHANG Tianyu, et al.

- Self-explosion defect detection method of glass insulator based on improved generative adversarial network[J]. *High Voltage Engineering*, 2022, 48(3): 1096-1103.
- [3] 崔昊杨, 韩 奕, 张 驯, 等. 基于改进 U-Net 结构生成对抗网络的运动模糊绝缘子图像复原方法[J]. *电网技术*, 2023, 47(6): 2594-2603.
- CUI Haoyang, HAN Yi, ZHANG Xun, et al. Motion blurred insulator image restoration method based on improved U-Net structure generative adversarial network[J]. *Power System Technology*, 2023, 47(6): 2594-2603.
- [4] 郝 帅, 马瑞泽, 赵新生, 等. 基于超分辨深度残差网络的玻璃绝缘子自爆故障检测算法[J]. *高电压技术*, 2022, 48(5): 1817-1825.
- HAO Shuai, MA Ruize, ZHAO Xinsheng, et al. Self-explosion fault detection algorithm for glass insulator based on super-resolution deep residual network[J]. *High Voltage Engineering*, 2022, 48(5): 1817-1825.
- [5] 卢 明, 高 超, 吴焱松, 等. 复合绝缘子脆性断裂与酥朽断裂差异性研究[J]. *高压电器*, 2022, 58(6): 17-23.
- LU Ming, GAO Chao, WU Yansong, et al. Study on difference between brittle fracture and decay-like fracture of composite insulator[J]. *High Voltage Apparatus*, 2022, 58(6): 17-23.
- [6] 刘开培, 李博强, 秦 亮, 等. 深度学习目标检测算法在架空输电线路绝缘子缺陷检测中的应用研究综述[J]. *高电压技术*, 2023, 49(9): 3584-3595.
- LIU Kaipei, LI Boqiang, QIN Liang, et al. Review of application research of deep learning object detection algorithms in insulator defect detection of overhead transmission lines[J]. *High Voltage Engineering*, 2023, 49(9): 3584-3595.
- [7] 王晓杰, 许 军, 林朝晖, 等. 输电线路复合绝缘子温升现象及其成因分析[J]. *电瓷避雷器*, 2022(5): 165-171.
- WANG Xiaojie, XU Jun, LIN Chaohui, et al. Analysis of the temperature rising of composite insulators of transmission lines[J]. *Insulators and Surge Arresters*, 2022(5): 165-171.
- [8] 刘立帅, 郭晨鋆, 王黎明, 等. 基于频域热特征成像的复合绝缘子缺陷检测方法[J]. *中国电机工程学报*, 2019, 39(8): 2498-2505.
- LIU Lishuai, GUO Chenyun, WANG Liming, et al. Defects detection method for composite insulators based on frequency thermal characteristics imaging[J]. *Proceedings of the CSEE*, 2019, 39(8): 2498-2505.
- [9] 谭宇璇, 樊绍胜. 基于图像增强与深度学习的变电设备红外热像识别方法[J]. *中国电机工程学报*, 2021, 41(23): 7990-7997.
- TAN Yuxuan, FAN Shaosheng. Infrared thermal image recognition of substation equipment based on image enhancement and deep learning[J]. *Proceedings of the CSEE*, 2021, 41(23): 7990-7997.
- [10] 裴少通, 马子儒, 刘云鹏, 等. 500 kV 输电线路劣化瓷绝缘子非线性发热特性的红外分析[J]. *高压电器*, 2024, 60(1): 33-40.
- PEI Shaotong, MA Ziru, LIU Yunpeng, et al. Infrared analysis of nonlinear heating characteristics of deteriorated porcelain insulator of 500 kV transmission lines[J]. *High Voltage Apparatus*, 2024, 60(1): 33-40.
- [11] ASHIKAGA H, ESTNER H L, HERZKA D A, et al. Quantitative assessment of single-image super-resolution in myocardial scar imaging[J]. *IEEE Journal of Translational Engineering in Health and Medicine*, 2014(2): 1-12.
- [12] LEI Sen, SHI Zhenwei, ZOU Zhengxia. Super-Resolution for remote sensing images via local-global combined network[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(8): 1243-1247.
- [13] DE FARIAS E C, DI NOIA C, HAN C H, et al. Impact of GAN-based lesion-focused medical image super-resolution on the robustness of radiomic features[J]. *Scientific Reports*, 2021, 11(1): 1-12.
- [14] 唐艳秋, 潘 泓, 朱亚平, 等. 图像超分辨率重建研究综述[J]. *电子学报*, 2020, 48(7): 1407-1420.
- TANG Yanqiu, PAN Hong, ZHU Yaping, et al. A survey of image super-resolution Reconstruction[J]. *Acta Electronica Sinica*, 2020, 48(7): 1407-1420.
- [15] 杨 悦, 谢 辛, 何 蕾, 等. 连分式插值结合卷积神经网络的超分辨率重建[J]. *合肥工业大学学报(自然科学版)*, 2021, 44(8): 1146-1152.
- YANG Yue, XIE Xin, HE Lei, et al. Super-resolution Reconstruction using deep convolutional neural network combined with continued fraction interpolation[J]. *Journal of Hefei University of Technology(Natural Science)*, 2021, 44(8): 1146-1152.
- [16] 刘云峰, 赵洪山, 杨晋彪, 等. 基于 GNR 先验的电力

- 设备热成像超分辨率方法[J]. 红外技术, 2023, 45(1): 40-48.
- LIU Yunfeng, ZHAO Hongshan, YANG Jinbiao, et al. Super resolution method for power equipment infrared imaging based on gradient norm-ratio prior[J]. Infrared Technology, 2023, 45(1): 40-48.
- [17]李方彪, 何昕, 魏仲慧, 等. 生成式对抗神经网络的多帧红外图像超分辨率重建[J]. 红外与激光工程, 2018, 47(2): 17-24.
- LI Fangbiao, HE Xin, WEI Zhonghui, et al. Multiframe infrared image super-resolution Reconstruction using generative adversarial networks[J]. Infrared and Laser Engineering, 2018, 47(2): 17-24.
- [18]DONG Chao, LOY C C, HE Kaiming, et al. Image Super-Resolution using deep convolutional networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(2): 295-307.
- [19]DONG Chao, LOY C C, TANG Xiao'ou. Accelerating the super-resolution convolutional neural network[C]// European Conference on Computer Vision.Springer, Cham: Springer International Publishing, 2016: 391-407.
- [20]KIM J, LEE J K, LEE K M. Accurate image Super-Resolution using very deep convolutional networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. [S.l.]: IEEE, 2016: 1646-1654.
- [21]LEDIG C, THEIS L, HUSZÁR F, et al. Photo-Realistic single image Super-Resolution using a generative adversarial network[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. [S.l.]: IEEE, 2017: 105-114.
- [22]赵洪山, 彭轶灏, 刘秉聪, 等. 基于边缘注意力生成对抗网络的电力设备热成像超分辨率重建[J]. 中国电机工程学报, 2022, 42(10): 3564-3572.
- ZHAO Hongshan, PENG Yihao, LIU Bingcong, et al. Super-resolution Reconstruction of electric equipment's thermal imaging based on generative adversarial network with edge-attention[J]. Proceedings of the CSEE, 2022, 42(10): 3564-3572.
- [23]刘志坚, 陶韵旭, 刘航, 等. 融合残差密集与生成对抗网络的红外巡检图像超分辨率重建[J]. 昆明理工大学学报(自然科学版), 2023, 48(5): 120-129.
- LIU Zhijian, TAO Yunxu, LIU Hang, et al. Super-resolution reconstruction of infrared inspection images by integrating residual dense and generative adversarial networks[J]. Journal of Kunming University of Science and Technology(Natural Science Edition), 2023, 48(5): 120-129.
- [24]韩龙, 刘凯雷, 左超, 等. 改进ESRGAN的电力设备红外图像超分辨率重建方法[J]. 黑龙江科技大学学报, 2023, 33(3): 445-450.
- HAN Long, LIU Kailei, ZUO Chao, et al. Super-resolution Reconstruction method for infrared images of power equipment with improved ESRGAN[J]. Journal of Heilongjiang University of Science and Technology, 2023, 33(3): 445-450.
- [25]ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein generative adversarial networks[C]//Proceedings of the 34th International Conference on Machine Learning. [S.l.]: [s.l.], 2017: 214-223.
- [26]GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
- [27]CHOLLET F. Xception: Deep learning with depthwise separable convolutions[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. [S.l.]: IEEE, 2017: 1800-1807.
- [28]GUO Menghao, XU Tianxing, LIU Jiangjiang, et al. Attention mechanisms in computer vision: A survey[J]. Computational Visual Media, 2022, 8(3): 331-368.
- [29]VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017(1): 6000-6010.
- 吴田(1983—), 男, 博士, 高级工程师, 主要从事电网智能运检和带电作业(E-mail: wutian_08@163.com)。
- 杨威(1999—), 男, 硕士研究生, 主要从事电网智能运检和图像处理(E-mail: weiyang_2021@163.com)。