

DOI: 10.19783/j.cnki.pspc.230687

# 基于改进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

王艳, 连洪钵, 王寅初, 康磊, 赵洪山

(华北电力大学电力工程系, 河北 保定 071000)

**摘要:** 针对低分辨率电力设备热成像图像, 提出一种基于改进边缘注意力生成对抗网络的超分辨率重建方法。首先, 在边缘注意力的基础上, 引入通道注意力和位置注意力的双注意力模块(dual attention, DA), 捕获特征图不同位置间和不同通道间的依赖关系, 并将两组依赖关系进行融合, 以加大全局信息的提取程度。然后针对参数修正线性单元激活函数(parametric rectified linear unit, PReLU)对网络中神经元进行无差别激活, 导致网络特征表达能力受限问题。采用改进  $\beta$ -ACONC 自适应控制激活函数替代 PReLU 函数, 在辨识有效特征的基础上, 对神经元进行选择性激活, 以强化有效特征、弱化无效特征, 提升网络的自适应激活能力和特征表达能力。最后对所提改进边缘注意力生成对抗网络模型(edge-attention generative adversarial network, EA-GAN)进行实验验证。结果表明, 与 BiCubic 双三次插值模型和原 EA-GAN 模型边缘注意力生成对抗网络模型相比, 所提改进模型网络性能最好, 重建图像质量最高, 客观评价指标峰值信噪比(peak signal-to-noise ratio, PSNR)均值、结构相似性(structural similarity, SSIM)均值和均方误差损失(mean square error loss, MSE-loss)均值最优, 在电力设备红外图像重建领域普适性较高, 具有一定的工程应用价值。

**关键词:** 热成像; 超分辨率重建; 注意力机制; 自适应激活函数

## Super-resolution reconstruction of thermal imaging of power equipment based on improved edge-attentive generative adversarial networks

WANG Yan, LIAN Hongbo, WANG Yinchu, KANG Lei, ZHAO Hongshan

(Department of Electric Power Engineering, North China Electric Power University, Baoding 071000, China)

**Abstract:** A super-resolution reconstruction method based on improved edge-attention generation adversarial network is proposed for low-resolution thermal imaging images of power equipment. First, using edge attention, a dual attention (DA) module of channel and position attention is introduced to capture the dependencies between different positions of the feature map and between different channels. The two sets of dependencies are fused to increase the degree of global information extraction. Then, to address the problem that the parametric rectified linear unit (PReLU) activation function performs undifferentiated activation on the neurons in the network, which leads to the limited feature expression capability of the network. The improved  $\beta$ -ACONC function is used to replace the PReLU function and selectively activate the neurons on the basis of identifying the effective features in order to strengthen effective features and weaken the ineffective features, and enhance the adaptive activation and feature expression capabilities of the network. Finally, the proposed improved edge-attention generative adversarial network (EA-GAN) model is experimentally validated. The results show that compared with BiCubic and the original EA-GAN model, the proposed improved model has the best network performance, the highest reconstructed image quality, and the best objective evaluation indices of peak signal-to-noise ratio (PSNR), structural similarity (SSIM) and mean square error loss (MSE-loss) mean values. These are universal in the field of infrared image reconstruction of power equipment and have a certain engineering application value.

This work is supported by the National Natural Science Foundation of China (No. 51807063).

**Key words:** thermal imaging; super-resolution reconstruction; attention mechanism; adaptive activation function

## 0 引言

红外热成像技术通过运用光电技术, 量化被

探测物体的红外辐射信号, 并将该信号转换成可供人类视觉分辨的图像和图形, 以表征被测物体的温度分布。随着红外热成像技术的发展, 其在电力系统中的应用也越来越广泛, 在电力设备的状态感知以及故障检测中起着不可或缺的作用<sup>[1-3]</sup>。但红外热

基金项目: 国家自然科学基金项目资助(51807063)

成像技术应用时受红外传感器安装成本以及数据传输、存储能力等条件制约,难以实现对现场大量电气设备高清红外图像的实时获取。因此为突破成本限制,采用图像处理算法提升红外图像清晰度,是实现红外热成像技术在电网中广泛应用的有效途径。

图像超分辨率重建是一种将模糊低分辨率图像重建为高清图像的技术,能够使图像在光学衍射极限频率以外复原出更为充足的纹理细节,被广泛应用在红外成像、视频处理<sup>[4]</sup>、人脸成像、医学成像等领域。

超分辨率重建方法主要包括三种:基于插值的方法、基于重建的方法和基于学习的方法。基于插值的超分算法包括最近邻插值<sup>[5-6]</sup>、双三次插值等<sup>[7-10]</sup>,插值方法原理简单且计算量小,但重建图像易出现细节丢失、纹理模糊等问题。基于重建的超分算法包括凸集投影法、迭代反投影法以及最大后验概率法等<sup>[11-14]</sup>,重建超分算法多为复杂数学算法,其运算量较大,不适合时间要求较高的场合。基于学习的超分算法包括稀疏编码法、流形学习等,因其对图像信息的恢复能力较强,故重建效果较好,而深度学习方法在主、客观评价指标上均有明显提升<sup>[15]</sup>,目前已成为超分辨率重建的主流方法。

超分辨率重建方法在深度学习领域主要分为卷积神经网络和生成对抗网络两大部分。文献[16]构建出超分辨率卷积神经网络模型(super-resolution convolutional network, CNN),低分辨率图像经过双三次插值放大到目标分辨率,再通过卷积层特征提取及非线性映射,重建得到高分辨率图像。在此基础上通过改变特征维数、添加反卷积层构建出特征超分辨率卷积神经网络模型(feature super-resolution convolutional neural network, RCNN)<sup>[17]</sup>。文献[18]将亚像素卷积层引入反卷积过程中,提出了高效亚像素卷积神经网络(efficient sub-pixel convolutional neural network, ESPCNN)<sup>[18]</sup>,提升了重建图像分辨率及重建速度。文献[19]提出了深度卷积神经网络(very deep super-resolution, VDSR)<sup>[19]</sup>,在网络结构中添加残差模块扩大网络感受野,并在此基础上提出深度递归卷积神经网络(deep recursive convolutional neural network, DRCNN)<sup>[20]</sup>。然而,上述基于卷积神经网络的重建模型最优网络层数难以确定,层数较少则网络性能较差,层数较多则模型收敛性难以保证。文献[21]在超分辨率重建领域首次引入生成对抗网络(super-resolution using a generative adversarial network, SRGAN)。文献[22]提出改进 Wasserstein 生成对抗网络,使 GAN 训练更加稳定。文献[23]将梯度惩罚项引入 Wasserstein 生成对抗网络,提出

带梯度惩罚的 Wasserstein 生成对抗网络(Wasserstein generative adversarial network with gradient penalty, WGAN-GP),提升网络收敛速度。文献[24]提出的边缘注意力生成式对抗网络(edge-attention generative adversarial network, EA-GAN),将边缘注意力机制添加到 WGAN-GP 网络的残差模块中,使得电力设备红外热成像重建后的边缘恢复度与整体感知效果更加理想。但 EA-GAN 网络仅加强了边缘特征的提取,未考虑全局信息相关性,且网络使用 PReLU 激活函数,对网络中所有神经元进行无差别激活,未区分特征有效性。

针对上述 EA-GAN 网络的不足,本文提出一种改进边缘注意力生成对抗网络。在边缘注意力的基础上,引入通道注意力和位置注意力的 DA 双注意力模块,捕获特征图中不同位置、不同空间的依赖关系,并将两组依赖关系进行融合,加大全局信息的提取程度。引入改进  $\beta$ -ACONC 激活函数替代原网络中的 PReLU 激活函数,在辨识有效特征的基础上,对神经元进行选择性地激活,进而强化有效特征、弱化无效特征、提升网络整体特征的表达能。实验验证表明采用所提改进 EA-GAN 算法重建得到的电力设备红外图像具有较高的客观指标评价和主观感知效果。

### 1 边缘注意力生成对抗网络

生成对抗网络是 Lan Goodfellow 等学者在 2014 年提出的一种新型的神经网络,可在无监督情况下进行自我学习。生成对抗网络结构如图 1 所示。网络整体分为两大部分,生成器  $G_g$  与判别器  $D_i$ ,其中,生成器  $G_g$  根据输入图像输出一组生成图像,判别器负责判别生成图像的真实性,两个网络通过交替训练达到博弈的效果,继而使生成器输出的生成图像与真实图像差距更小,模拟度更高。生成器与判别器之间的博弈目标函数可用式(1)表示。

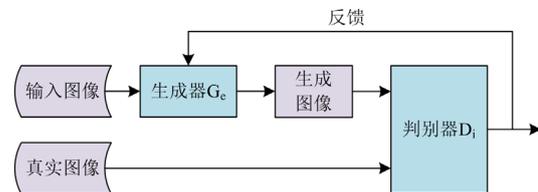


图 1 生成对抗网络结构

Fig. 1 Generating adversarial network structure

$$\min_{G_g} \max_{D_i} V(D_i, G_g) = E_{x \sim P_x} [\log D_i(x)] + E_{z \sim P_z} [\log(1 - D_i(G_g(z)))] \quad (1)$$

式中:  $E[\cdot]$  表示期望运算;  $x$  表示真实图像数据,分布服从  $P_x$ ;  $D_i(\cdot)$  表示判别器的判别结果;  $z$  表

示输入图像数据, 分布服从  $P_2$ ;  $G_c(z)$  表示生成器的生成图像数据。

原始生成对抗网络中, 生成器  $G$  的深度残差模块由卷积层-BN层-PReLU层-卷积层-BN层构成。而边缘注意力生成对抗网络(EA-GAN)则是在生成器  $G$  的深度残差模块中, 引入边缘注意力机制(edge-attention, EA), 如图 2 所示。不同区域相连的边缘部分, 其数据信息属性会发生突变, 需要重点关注。而边缘注意力机制是将原本平均分配的资源, 通过注意力对象的重要程度, 按相应指标权重重新分配, 进而增强边缘信息对通道的影响程度, 增强生成图像的细节纹理, 以提升网络表征能力和学习能力。

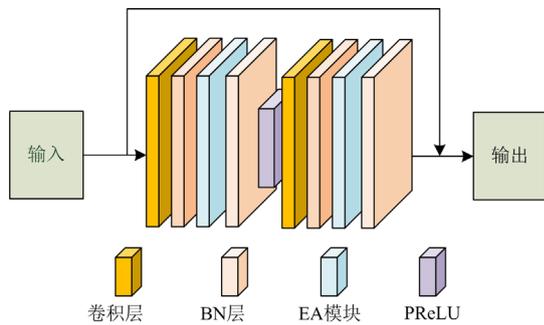


图 2 引入边缘注意力的深度残差模块

Fig. 2 Depth residual module with the introduction of edge attention

EA-GAN 网络运用博弈论思想, 将生成器网络与判别器网络进行对抗, 强化了边缘特征的提取与重建能力<sup>[28]</sup>, 但对全局信息的提取能力相对不足。且 EA-GAN 网络的生成器采用传统激活函数 PReLU, 对网络中所有神经元采用无差别激活, 不区别有效特征和无效特征, 削弱了网络有效特征的表达能力, 影响了网络的学习效果。针对上述缺陷, 本文提出了改进边缘注意力生成对抗网络。

## 2 改进边缘注意力生成对抗网络

针对 EA-GAN 网络的不足, 本文提出一种改进边缘注意力生成对抗网络, 以提升电力设备红外热成像的重建能力。改进之处如下所述。

1) 在边缘注意力的基础上, 引入通道注意力和位置注意力的 DA 双注意力模块。通道注意力可以捕获特征图中任意两个通道映射间的依赖关系, 位置注意力可以捕获特征图中任意两个位置之间的空间依赖关系, 将两组依赖关系进行融合, 以凸显特征图中各元素间的特征依赖, 继而加大全局信息的提取程度, 弥补原 EA-GAN 模型对全局信息提取能力不足的缺陷。

2) 针对原 EA-GAN 模型使用 PReLU 激活函数

对网络中神经元进行无差别激活, 导致网络特征表达能力受限问题, 本文采用改进  $\beta$ -ACONC 激活函数代替原网络中的 PReLU 激活函数, 在辨识有效特征的基础上, 对神经元进行选择性激活, 进而强化有效特征, 弱化无效特征, 提升网络整体特征的表达能力。

本文所提改进边缘注意力生成对抗网络的生成器结构如图 3 所示。在图 2 深度残差模块的基础上引入 DA 双注意力模块, 替换原模块中第二个 EA 模块; 采用改进  $\beta$ -Aconc 激活函数代替原生成器中的 PReLU 激活函数。同时在判别器的残差模块中增加 DA 模块。

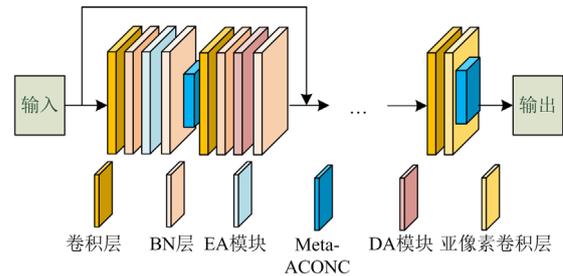


图 3 改进的 EA-GAN 生成器

Fig. 3 Improved EA-GAN generator

### 2.1 DA 双注意力模块

根据电力设备的红外图像进行设备的状态感知以及故障检测时, 不仅需要观察其边缘细节, 而且其内部特征同样值得重视。而原 EA-GAN 网络只关注了图像边缘细节的提取能力, 未加强对图像内部特征的提取。为加大全局信息提取程度, 提升电力设备红外图像的整体重建能力, 本文在原 EA-GAN 网络的基础上引入 DA 双注意力模块。

DA 双注意力模块包含通道注意力 CAM 与位置注意力 PAM 两个子模块, 两者采取并联结构, 如图 4 所示。通道注意力模块对输入特征图通道域的特征相关性进行充分挖掘, 加强通道映射间的依赖关系; 位置注意力模块对输入特征图空间域的特征相关性进行充分挖掘, 加强位置空间的依赖关系; 最后两子模块输出特征矩阵以 element-wise sum 方

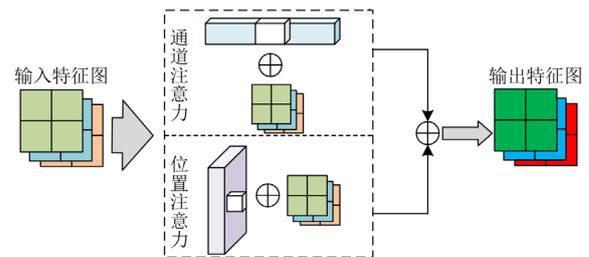


图 4 双注意力模块整体框架

Fig. 4 Framework of the dual attention module

式进行融合, 兼顾了通道域和位置域, 加大了全局信息的提取程度。

### 2.1.1 通道注意力模块 CAM

CAM 通道注意力模块结构如图 5 所示, 运行顺序如下。

1) 将尺寸为  $C \times H \times W$  ( $C$  为特征图的通道数,  $H$ 、 $W$  分别为特征图的高与宽) 的特征图 A 进行像素重组, 重构得到尺寸为  $C \times N$  ( $N = H \times W$ ) 的特征矩阵  $B$ 。

2) 重构特征矩阵  $B$  与其转置矩阵  $B^T$  相乘, 通过 Softmax 层计算得到尺寸为  $C \times C$  的通道注意力特征矩阵  $X$ ,  $X \in R^{C \times C}$ 。

$$X = BB^T \quad (2)$$

$$x_{ij} = \frac{\exp\left[\sum_{r=1}^C (B_{ir} \cdot B_{rj}^T)\right]}{\sum_{i=1}^C \exp\left[\sum_{r=1}^C (B_{ir} \cdot B_{rj}^T)\right]} = \frac{\exp(B_i \cdot B_j)}{\sum_{i=1}^C \exp(B_i \cdot B_j)} \quad (3)$$

式中:  $x_{ij}$  是通道注意力特征矩阵  $X$  中的对应元素

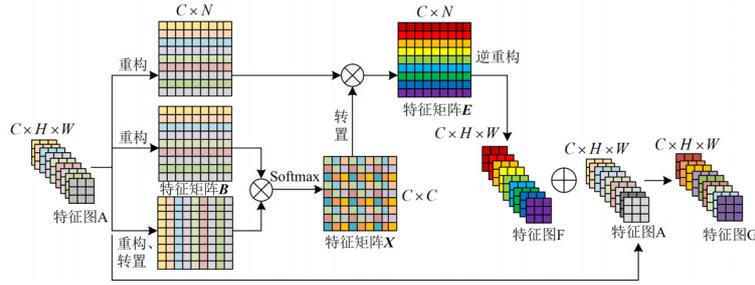


图 5 CAM 模块示意图

Fig. 5 Schematic diagram of CAM module

### 2.1.2 PAM 位置注意力模块

PAM 位置注意力模块结构如图 6 所示, 运行顺序如下:

1) 将特征图 A 通过卷积层生成新的特征矩阵  $B \in R^{C \times H \times W}$ 、 $D \in R^{C \times H \times W}$ 、 $F \in R^{C \times H \times W}$ , 以加强全局信息交互、拓宽感受野、增强后续网络重建的表征能力。

2) 对特征矩阵  $B$ 、 $D$ 、 $F$  进行像素重组, 重构尺寸为  $C \times N$  ( $N = H \times W$ ) 的特征矩阵  $B'$ 、 $D'$  和  $F'$ 。

3) 将重构特征矩阵  $D'$  的转置与矩阵  $B'$  相乘, 通过 Softmax 层计算得到尺寸为  $N \times N$  的位置注意力矩阵  $S$ ,  $S \in R^{N \times N}$ 。

$$S = D'^T B' \quad (7)$$

$$s_{ij} = \frac{\exp\left[\sum_{r=1}^C (D'_{ir} \cdot B'_{rj})\right]}{\sum_{i=1}^C \exp\left[\sum_{r=1}^C (D'_{ir} \cdot B'_{rj})\right]} = \frac{\exp(D'_{i列} \cdot B'_{j列})}{\sum_{i=1}^C \exp(D'_{i列} \cdot B'_{j列})} \quad (8)$$

值, 表示通道  $j$  对通道  $i$  的影响因子;  $B_i$ 、 $B_j$  分别为重构特征矩阵  $B$  中第  $i$  行(通道  $i$ ) 和第  $j$  行(通道  $j$ ) 的对应元素, 其中矩阵  $B$  的第  $j$  行对应矩阵  $B^T$  的第  $j$  列。

3) 将通道注意力特征矩阵  $X$  转置后与矩阵  $B$  相乘, 得到特征矩阵  $E$ ,  $E \in R^{C \times N}$ 。

$$E = X^T B \quad (4)$$

$$E_{ij} = \sum_{r=1}^C (x_{ri} B_{rj}) \quad (5)$$

式中,  $E_{ij}$  为矩阵  $E$  中第  $i$  行第  $j$  列的对应元素。

4) 将矩阵  $E$  逆重组为尺寸为  $C \times H \times W$  的特征图  $F$ 。特征图  $F$  乘以权值  $\beta$  与特征图  $A$  相加, 得到最终的通道注意力特征图  $G$ ,  $G$  中每个通道的对应元素值  $G_{ij}$  为

$$G_{ij} = \beta F_{ij} + A_{ij} \quad (6)$$

式中:  $F_{ij}$  表示重构特征图  $F$  中的对应元素;  $A_{ij}$  表示原特征图  $A$  中的对应元素。

式中:  $s_{ij}$  是位置注意力特征矩阵  $S$  中的对应元素值, 表示位置  $j$  对位置  $i$  的影响因子,  $s_{ij}$  的大小反映位置  $i$  与  $j$  的相关性;  $D'_{i列}$  为重构特征矩阵  $D'$  第  $i$  列对应元素(对应特征图  $D$  中同一位置不同通道的元素);  $B'_{j列}$  为重构特征矩阵  $B'$  中的第  $j$  列对应元素。

4) 将特征矩阵  $F'$  乘以注意力矩阵  $S$  的转置, 得到特征矩阵  $H$ ,  $H \in R^{C \times N}$ 。

$$H = F'^T S \quad (9)$$

$$H_{ij} = \sum_{r=1}^N (F'_{ir} \cdot s_{jr}) \quad (10)$$

式中,  $H_{ij}$  为矩阵  $H$  中第  $i$  行第  $j$  列的对应元素。

5) 将矩阵  $H$  逆重组为尺寸为  $C \times H \times W$  的特征图  $I$ 。特征图  $I$  乘以权值  $\alpha$  与特征图  $A$  相加, 得到最终的位置注意力特征图  $K$ ,  $K$  中每个通道的对应元素值  $K_{ij}$  为

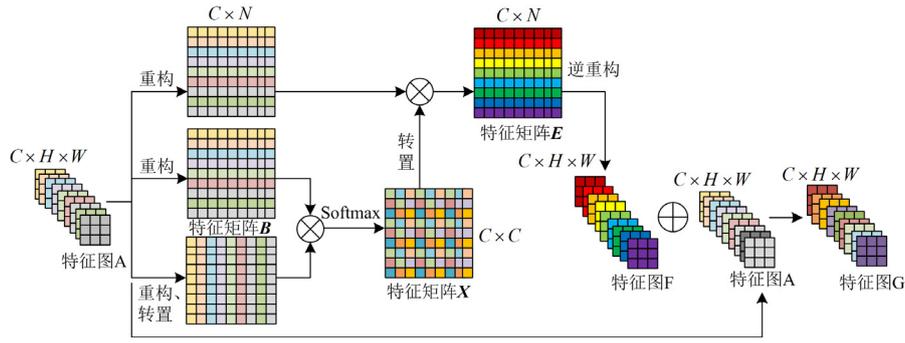


图 6 PAM 模块示意图

Fig. 6 Schematic diagram of PAM module

$$K_{ij} = \alpha I_{ij} + A_{ij} \quad (11)$$

## 2.2 改进 $\beta$ -ACONC 自适应激活函数

在进行电力设备红外图像重建时, 模型采用不同的激活函数导致网络的特征表达能力不同, 继而影响了图像的重建质量, 故本节对重建模型的激活函数进行了对比研究。

传统 GAN 模型中使用的是 ReLU 激活函数, ReLU 激活函数<sup>[31]</sup>具有稀疏性、非饱和等特性, 长期作为神经网络的激活函数, 但其存在部分神经元坏死现象, 将对神经网络的学习过程产生影响, 使得图像重建质量降低。而 ACON<sup>[33]</sup>激活函数能够动态控制网络的线性与非线性程度, 增强了网络特征的学习表达能力, 使网络模型拥有更高的重建精度。

ACON 激活函数是在 Maxout 系列函数的基础上发展起来的。 $\max(\eta_a(x), \eta_b(x))$  作为 Maxout 系列函数的通用最简形式, 对其进行可微近似, 得到 ACON 激活函数的表达式  $S_\beta[\eta_a(x), \eta_b(x)]$ 。

$$S_\beta[\eta_a(x), \eta_b(x)] = [\eta_a(x) - \eta_b(x)] \cdot \sigma\{\beta[\eta_a(x) - \eta_b(x)]\} + \eta_b(x) \quad (12)$$

式中:  $\eta_a(x)$ 、 $\eta_b(x)$  表示输入的线性函数;  $\sigma$  为 Sigmoid 函数;  $\beta$  为平滑因子。

如表 1 所示, 当式(1)中线性函数  $\eta_a(x)$ 、 $\eta_b(x)$  取不同值时, 对应 ACON 激活函数 A、B、C 三种不同形式。其中, ACON-C 激活函数可通过  $p1$ 、 $p2$  自适应调整函数梯度上下限, 实现函数线性与非线性间的灵活转换, 其性能最优, 应用较为广泛。但 ACON-C 激活函数中, 平滑因子  $\beta$  由激活函数自主学习得到, 并将其应用于特征图所有通道中, 使得各通道平滑因子  $\beta$  一致, 导致特征图被激活形式较为单一, 模型泛化能力受限。

针对上述问题, 本文提出一种改进  $\beta$ -ACONC 激活函数。改进激活函数中, 平滑因子  $\beta$  由改进自适应模块动态学习得到, 不同通道采用不同的  $\beta$

值, 从而控制对应通道的非线性激活程度, 为每一通道定制自适应的激活函数。

表 1 Maxout 函数与 ACON 函数表

Table 1 Maxout function and ACON function table

| $\eta_a(x)$ | $\eta_b(x)$ | Maxout               | ACON   |
|-------------|-------------|----------------------|--------|
| x           | 0           | $\max(x, 0)$ :ReLU   | ACON-A |
| x           | px          | $\max(x, px)$ :PReLU | ACON-B |
| p1x         | p2x         | $\max(p1x, p2x)$     | ACON-C |

改进自适应模块如图 7 所示。在 channel-wise 空间内, 首先输入通道  $r(r \in (1, C))$  的特征矩阵  $R \in R^{H \times W}$ , 分别对特征矩阵  $R$  求取行列均值, 得均值矩阵  $M \in R^{H \times 1}$ 、 $N \in R^{1 \times W}$ 。 $M$ 、 $N$  中元素表达式分别为

$$\begin{cases} M_{i1} = \frac{1}{W} \sum_{j=1}^W R_{ij} \\ N_{1j} = \frac{1}{H} \sum_{i=1}^H R_{ij} \end{cases} \quad (13)$$

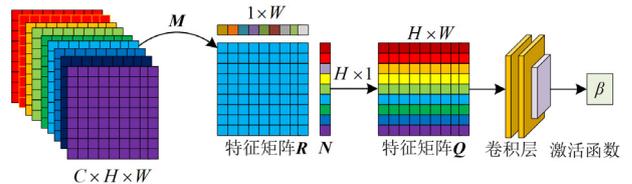


图 7 改进自适应模块示意图

Fig. 7 Schematic diagram of the improved adaptive module

为体现该通道特征矩阵信息的丰富程度, 将均值矩阵  $M$  与  $N$  相乘, 得到新的均值特征矩阵  $Q$ 。特征矩阵  $Q$  经两个卷积层, 以共享本通道所有像素的特征权重。最后通过 Sigmoid 激活函数得到本通道的平滑因子  $\beta$ 。

$$Q = MN \quad (14)$$

$$\beta = \sigma W_1 W_2 Q \quad (15)$$

式中:  $\sigma$  为 Sigmoid 激活函数;  $W_1$ 、 $W_2$  表示卷积层。

图 8 是 ACON 函数和改进  $\beta$ -ACONC 函数的激活程度对比图。图 8(a)中, 蓝色 ACON 表示网络选择激活该通道, 红色 ACON 表示网络不激活该通道。而图 8(b)中, 由于每个通道的平滑因子  $\beta$  经各自的改进自适应模块得到, 故每个通道的  $\beta$ -ACON 采用不同颜色, 表示不同的网络激活程度。改进  $\beta$ -ACONC 激活函数通过自适应动态调整平滑因子  $\beta$ , 使得特征图激活形式多样, 模型泛化能力大大提升, 从而有效提高网络传递性能。

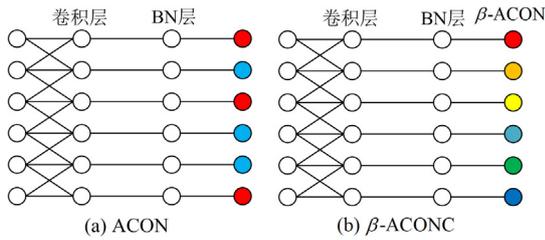


图 8 函数激活程度对比图

Fig. 8 Comparison of function activation level

### 3 实验分析

算法程序基于 pytorch 框架运行, 神经网络学习的 GPU 为 NVIDIA GTX1080Ti, 硬件运行环境为 CUDA10.1, CUDNN7.6.4, 8 G。实验中的电力设备热成像数据集为作者自行收集的 952 张图像, 包括输电线路绝缘子、变电站电力设备、单相干式变压器、感应电机和光伏发电系统等设备红外图像。其中训练集占比 90%, 测试集占比 10%。将原始电力设备热成像图像进行  $200 \times 200$  像素切割, 并进行四倍下采样作为低分辨训练图像, 将原始图像作为判别器中目标高分辨图像, 在 TensorFlow 框架下进行实时训练追踪。将峰值信噪比(PSNR)、结构相似度(SSIM)以及均方误差(MSE)作为重建结果的分析评价指标。

本文将所提改进方法与原 EA-GAN 方法所得超分辨重构图像进行了分析比较。

#### 3.1 训练过程分析

本文记录网络学习迭代过程中每次迭代对应的平均 PSNR、SSIM 以及 MSE 数据, 经 Savitzky-Golay 滤波器绘制曲线图 9—图 11, 滤波器参数设置为: `window_length = 11`、`polyorder = 7`。

由图 9—图 11 可知, 训练过程中, 在迭代次数相同的情况下, 本文所提改进 EA-GAN 算法与原 EA-GAN 算法相比, 其 PSNR 均值和 SSIM 均值均有明显提升, MSE 均值有一定程度降低; 且迭代过程中改进 EA-GAN 算法各评价指标变化更为平稳,

波动范围更小。表明本文所提改进 EA-GAN 算法具有更高的图像感知质量和更好的图像重建效果。

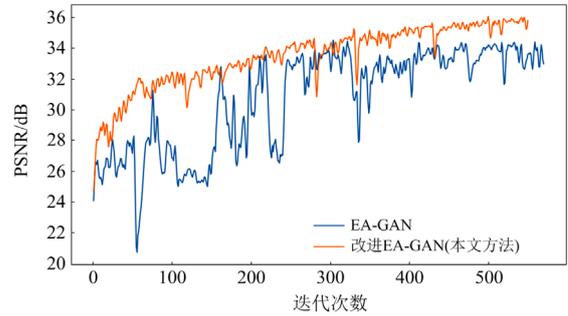


图 9 训练集 PSNR 迭代曲线

Fig. 9 Iteration curve of PSNR for training set

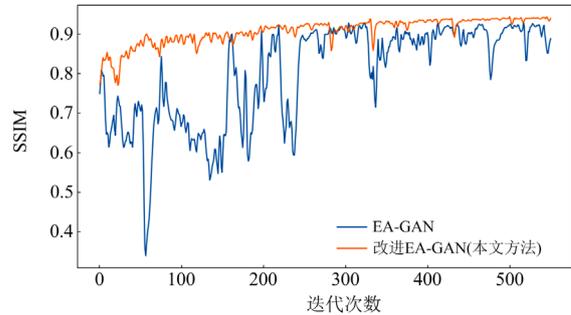


图 10 训练集 SSIM 迭代曲线

Fig. 10 Iteration curve of SSIM for training set

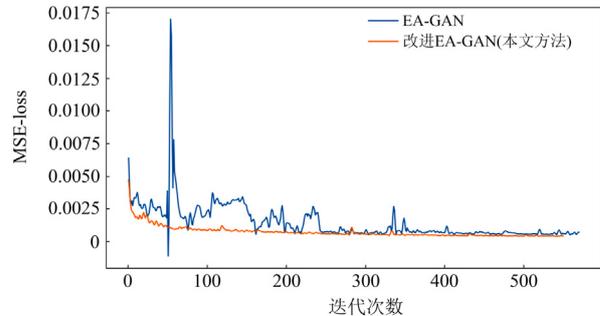


图 11 训练集 MSE-loss 迭代曲线

Fig. 11 Iteration curve of MSE-loss of training set

#### 3.2 测试结果分析

为验证所提改进 EA-GAN 算法的各改进之处对图像重建效果的提升, 本文针对同一电气设备的红外图像, 采用不同的改进模型进行超分辨率重建, 并将各重建图像的评价指标进行对比分析, 结果如表 2 所示。

由表 2 可知, 与原 EA-GAN 模型相比,  $\beta$ -EA-GAN 模型因  $\beta$ -ACONC 激活函数的引入, 使得不同通道对应不同的激活程度, 模型激活形式多样, 特

征表达能力较强,其 PSNR 均值升高了 0.196 dB, SSIM 均值升高了 0.009, MSE 值降低了 1.2%。DA-EA-GAN 模型因 DA 双注意力模块的引入,充分挖掘了图像空间域和通道域的特征依赖关系,加强了模型全局信息的提取能力,使得模型评价指标得到进一步提升,PSNR 均值升高了 0.421 dB,SSIM 均值升高了 0.013, MSE 值降低了 10.9%。而本文方法将  $\beta$ -ACONC 激活函数及 DA 双注意力模块相结合,兼顾了网络特征的表达能力和全局信息的特征提取能力,使得模型重建效果更优,评价指标最高,较原 EA-GAN 模型 PSNR 均值升高了 0.911 dB, SSIM 均值升高了 0.038, MSE 值降低了 16.7%。可见,本文所提改进点可以有效提升网络的图像重建能力,在电力设备热成像重建领域具有较高的应用潜能。

表 2 所提改进点评价指标对比

Table 2 Comparison of evaluation indicators of the proposed improvement points

| 评价指标            | PSNR/dB | SSIM   | MSE                     |
|-----------------|---------|--------|-------------------------|
| EA-GAN          | 32.342  | 0.887  | $7.3442 \times 10^{-4}$ |
| $\beta$ -EA-GAN | 32.538  | 0.896  | $7.2549 \times 10^{-4}$ |
| DA-EA-GAN       | 32.763  | 0.9001 | $6.5364 \times 10^{-4}$ |
| 本文方法            | 33.253  | 0.9251 | $6.1152 \times 10^{-4}$ |

为进一步验证所提改进 EA-GAN 算法的优越性,本文对比分析了基于双三次插值 BiCubic、原 EA-GAN 和所提改进 EA-GAN 三种算法的图像重建效果。表 3 给出了 3 种算法对输电线路绝缘子热成像重建图像的评价指标。图 12 给出了利用 3 种算法对不同电力设备红外图像的重建效果图,包括:输电线路绝缘子热成像、变压器热成像、主变低压套管热成像、主变中性点电抗器热成像。图 12 中从左至右分别为低分辨率图像、BiCubic 重建图像,EA-GAN 重建图像、改进 EA-GAN 重建图像。图 13 给出了对应设备重建图像的评价指标。

表 3 重建图像评价指标对比

Table 3 Comparison of evaluation indexes of reconstructed images

| 评价指标    | BiCubic                 | EA-GAN                  | 本文方法                    |
|---------|-------------------------|-------------------------|-------------------------|
| PSNR/dB | 27.342                  | 32.491                  | 33.396                  |
| SSIM    | 0.881                   | 0.907                   | 0.931                   |
| MSE     | $2.1564 \times 10^{-3}$ | $7.2008 \times 10^{-4}$ | $6.0558 \times 10^{-4}$ |

由表 3 可知,本文所提改进算法在 PSNR 均值上较原 EA-GAN 算法提高了 0.905 dB,较 BiCubic 算法提高了 6.004 dB;在 SSIM 均值上较原 EA-GAN 算法提高了 0.024,较 BiCubic 算法提高了 0.05;在 MSE 上较原 EA-GAN 算法降低了 15.9%,相对于

BiCubic 降低了 70.69%。

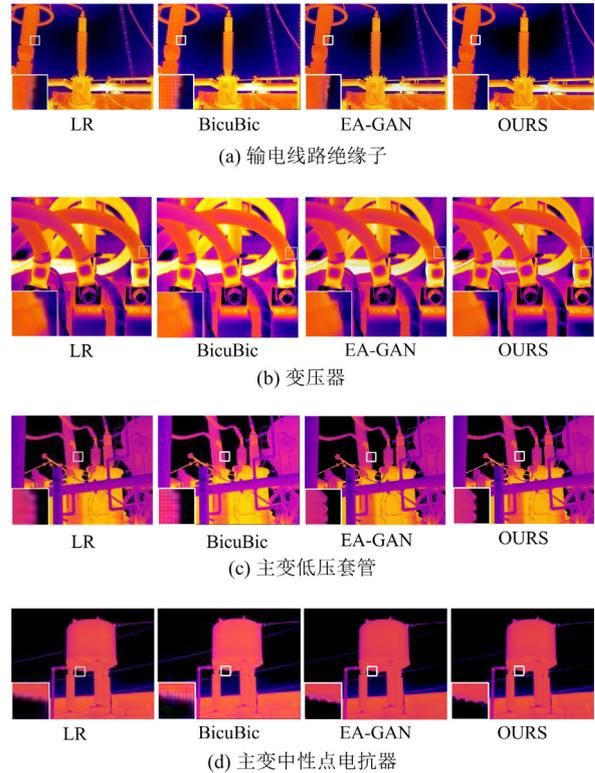


图 12 重建图像整体感官视觉比较

Fig. 12 Overall sensory visual comparison of reconstructed images

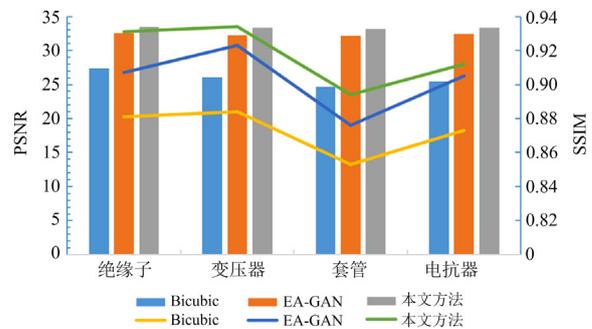


图 13 重建图像的评价指标对比

Fig. 13 Comparison of evaluation indexes of reconstructed images

由图 12 设备重构图像局部细节放大图可知, BiCubic 方法重建图像块效应明显且边缘较模糊, EA-GAN 方法重建图像清晰度有所提升,而本文方法重建图像在边缘清晰度及整体细节上相对于 BiCubic、EA-GAN 方法有明显提升,其中,输电线路绝缘子以及主变低压套管边缘纹路更清晰,变压器以及主变中性点电抗器重建图像整体感官更好。且由图 13 可知,本文方法所得各电力设备重建图像客观评价

指标均为最高。可见本文方法在电力设备红外图像的重建上误差最低, 图像纹理特征恢复程度最好。

为验证本文方法在实际工程应用中的效果, 图 14 给出了现场拍摄的、无高分辨率原图的、低分辨率电力设备红外图像, 及对其进行超分辨率重建的效果图。由图 14 可知, 本文方法重建图像边缘轮廓清晰、纹理信息丰富, 视觉质量较好。在电力设备红外图像重建领域普适性较高, 具有一定的工程应用价值。

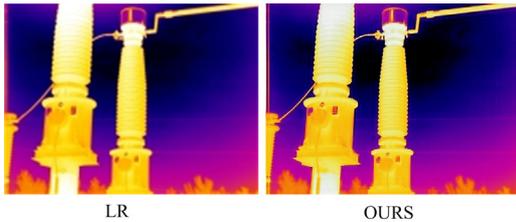


图 14 低分辨率重建图像效果图

Fig. 14 Effect of low-resolution reconstructed image

#### 4 结论

本文提出一种改进 EA-GAN 模型用于电力设备红外图像的重建。以电力设备红外图像为输入样本, 通过引入双注意模块和  $\beta$ -ACONC 函数改进原 EA-GAN 模型, 改进后生成器与判别器相互博弈, 最终生成与原始高清图象差距较小的电力设备红外图像, 并通过与其他方法对比验证了模型的有效性。得出结论如下:

1) 改进 EA-GAN 模型在边缘注意力的基础上, 引入通道注意力和位置注意力的 DA 双注意力模块, 分别捕获特征图中不同位置间和不同通道间的依赖权重, 并将两组权重分别与原有的特征进行融合, 以凸显特征图中各元素间的特征依赖, 继而加大全局信息的提取程度, 提升网络模型的特征学习能力。

2) 针对原 EA-GAN 模型使用 PReLU 激活函数对神经元进行无差别激活, 导致网络特征表达能力受限、无用信息参数量过大问题, 本文引入  $\beta$ -ACONC 激活函数代替 PReLU 激活函数, 在辨识有效特征的基础上, 对神经元进行选择性的激活, 以强化有效特征、弱化无效特征, 增强网络的自适应激活能力和特征表达能力。

3) 实验表明, 与 BiCubic 模型、原 EA-GAN 模型相比, 改进的 EA-GAN 模型在电力设备红外图像的重建过程中, 其客观评价指标 PSNR 均值、SSIM 均值和 MSE 均值均为最优, 重建图像整体感官视觉效果最好, 具有较高的工程应用价值。

#### 参考文献

[1] 袁培, 王船仲, 毛文奇, 等. 基于多重生对抗网络的

智能开关设备状态感知与诊断研究[J]. 电力系统保护与控制, 2021, 49(6): 68-74.

YUAN Pei, WANG Bozhong, MAO Wenqi, et al. Research on state perception and diagnosis of intelligent switches based on triple generative adversarial networks[J]. Power System Protection and Control, 2021, 49(6): 68-74.

[2] 周可慧, 廖志伟, 陈琳韬, 等. 基于双重背景分离及自适应网格的电压致热型设备红外图像状态分析[J]. 电力系统保护与控制, 2019, 47(24): 124-130.

ZHOU Kehui, LIAO Zhiwei, CHEN Lintao, et al. Research on state analysis of voltage-heating equipment based on dual background separation and adaptive meshing of infrared image[J]. Power System Protection and Control, 2019, 47(24): 124-130.

[3] 刘科研, 周方泽, 周晖. 基于时序信号图像编码和生成对抗网络的配电网台区数据修复[J]. 电力系统保护与控制, 2022, 50(24): 130-136.

LIU Keyan, ZHOU Fangze, ZHOU Hui. Missing data imputation in a transformer district based on time series imaging encoding and a generative adversarial network[J]. Power System Protection and Control, 2022, 50(24): 130-136.

[4] 刘谋海, 胡军华, 丁国栋, 等. 基于深度学习的电力监控视频超分辨率重建[J]. 电力系统保护与控制, 2021, 49(11): 182-186.

LIU Mouhai, HU Junhua, DING Guodong, et al. Super-resolution reconstruction of a power monitoring video based on deep learning[J]. Power System Protection and Control, 2021, 49(11): 182-186.

[5] FU Ying, ZHANG Tao, ZHENG Yinqiang, et al. Hyperspectral image super-resolution with optimized RGB guidance[C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA: 11653-11662.

[6] ZHANG Lei, NIE Jiangtao, WEI Wei, et al. Unsupervised adaptation learning for hyper spectral imagery super-resolution[C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA: 3070-3079.

[7] LI Sheng, HE Fengxiang, DU Bo, et al. Fast spatiotemporal residual network for visio super-resolution[C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA: 10514-10523.

[8] SONG Huihui, XU Wenjie, LIU Dong, et al. Multi-stage feature fusion network for visio super-resolution[J]. IEEE Transactions on Image Processing, 2021, 30: 2923-2934.

[9] TIAN Yapeng, ZHANG Yulun, FU Yun, et al. TDAN:

- temporally-deformable alignment network for video super-resolution[C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA: 3357-3366.
- [10] 曾凯, 丁世飞. 图像超分辨率重建的研究进展[J]. 计算机工程与应用, 2017, 53(16): 29-35  
ZENG Kai, DING Shifei. Advances in image super-resolution reconstruction[J]. Computer Engineering and Applications, 2017, 53(16): 29-35.
- [11] MEISHVILI G, JENNI S, FAVARO P. Learning to have an ear for face super-resolution[C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA: 1361-1371.
- [12] MA Cheng, JIANG Zhenyu, RAO Yongming, et al. Deep face super-resolution with iterative collaboration between attentive recovery and landmark estimation[C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA: 5568-5577.
- [13] SOOD R, RUSU M. Anisotropic super resolution in prostate MRI using super resolution generative adversarial networks[C] // 2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019), April 8-11, 2019, Venice, Italy: 1688-1691.
- [14] YANG Wenming, ZHANG Xuecheng, TIAN Yapeng, et al. Deep learning for single image super-resolution: a brief review[J]. IEEE Transactions on Multimedia, 2019, 21(12): 3106-3121.
- [15] 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.
- [16] DONG Chao, LOY C C, TANG Xiaoou. Accelerating the super-resolution convolutional neural network[C] // Proceeding of 14th European Conference on Computer Vision, Amsterdam, Netherlands: Springer, 2016: 391-407.
- [17] SHI Wenzhe, CABALLERO J, HUSZAR F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network[C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas NV, USA: 1874-1883.
- [18] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks[C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA: 1646-1654.
- [19] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution[C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), July 21-26, 2017, Honolulu, HI, USA: 1132-1140.
- [20] KIM J, LEE J K, LEE K M. Deeply-recursive convolutional network for image super-resolution[C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) June 27-30, 2016, Las Vegas, NV, USA: 1637-1645.
- [21] LEDIG C, THEIS L, HUSZAR F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA: 105-104.
- [22] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein generative adversarial networks[C] // Proceedings of the 34th International Conference on Machine Learning, 2017, Sydney, Australia: 214-223.
- [23] GULRAJAN I, AHMED F, ARJOVSKY M, et al. Improved training of Wasserstein GANs[C] // Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017, Red Hook: 5769-5799.
- [24] 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.

收稿日期: 2023-06-06; 修回日期: 2023-07-19

作者简介:

王艳(1981—), 女, 博士, 副教授, 研究方向为电气设备在线监测与故障诊断、电力系统保护与控制; E-mail: wang\_yan()421@163.com

连洪钵(1999—), 男, 通信作者, 硕士研究生, 研究方向为红外热图像超分重建。E-mail: 1668616165@qq.com

(编辑 魏小丽)