

DOI: 10.19783/j.cnki.pspc.240741

考虑局部纹理特征和全局温度分布的电力设备红外图像超分辨率重建方法

赵洪山¹, 王惠东¹, 刘婧萱¹, 杨伟新², 李忠航¹, 林诗雨¹, 余洋¹, 吕廷彦¹

(1. 华北电力大学电气与电子工程学院, 河北 保定 071003; 2. 国网冀北电力有限公司电力科学研究院, 北京 100045)

摘要: 针对传统电力设备红外图像超分辨率重建方法缺乏对设备局部纹理特征和全局温度分布的考虑导致重建后图像分辨率较低的问题, 提出一种基于 Transformer-GAN 聚合网络的电力设备超分辨率重建方法。首先, 基于移位卷积设计电力设备局部特征提取模块, 在不增加参数情况下扩展卷积的感受野, 提取电力设备局部纹理及其周围不同空间维度特征的信息。然后, 引入全局特征提取模块, 通过深度卷积和空间注意力机制捕捉图像不同区域间温度分布的关联性。最后, 采用 UNet 编解码器网络融合各层局部特征和全局表示, 生成清晰自然的电力设备红外图像。算例结果表明, 所提方法的峰值信噪比(peak signal-to-noise ratio, PSNR)、结构相似性(structural similarity, SSIM)、和视觉信息保真度(visual information fidelity, VIF)三项评价指标均优于其他方法。同时它具有良好的主观视觉效果, 泛化能力较强。

关键词: 电力设备; 红外图像; 超分辨率重建; 局部纹理特征; 全局温度分布; Transformer-GAN

Super-resolution reconstruction method for infrared images of power equipment considering local texture features and global temperature distribution

ZHAO Hongshan¹, WANG Huidong¹, LIU Jingxuan¹, YANG Weixin², LI Zhonghang¹, LIN Shiyu¹, YU Yang¹, LÜ Tingyan¹

(1. School of Electrical and Electronic Engineering, North China Electric Power University, Baoding 071003, China;
2. State Grid Jibei Electric Power Research Institute, Beijing 100045, China)

Abstract: To address the problem of low resolution in reconstructed image due to the lack of consideration for local texture features and global temperature distribution in traditional super-resolution reconstruction methods for infrared images of power equipment, a super-resolution reconstruction method based on Transformer-GAN aggregation network is proposed. Firstly, a local feature extraction module for power equipment is designed based on shift convolution, which expands the receptive field of the convolution without increasing parameters, extracting local texture and surrounding spatial dimension features of the power equipment. Then, a global feature extraction module is introduced to capture the correlation of temperature distributions between different regions of the image through deep convolution and spatial attention mechanisms. Finally, the UNet encoder-decoder network is used to fuse the local features and global representations at each layer, generating clear and natural infrared images of power equipment. The case study results show that the proposed method outperforms other methods in terms of peak signal to noise ratio (PSNR), structural similarity (SSIM), and visual information fidelity (VIF). It also has good subjective visual effects and strong generalization ability.

This work is supported by the National Natural Science Foundation of China (No. 52077078).

Key words: power equipment; infrared image; super-resolution reconstruction; local texture features; global temperature distribution; Transformer-GAN

0 引言

随着“三型两网, 世界一流”目标的提出, 全

面感知整个电网的运行信息、故障类型和设备状态成为建设泛在电力物联网的关键环节, 各类在线监测设备的攻关研发和部署应用显得极为迫切^[1-3]。红外热成像传感器在电力设备的状态感知及故障检测中起着不可或缺的作用, 然而, 当前的红外成像技术依然存在着信噪比低、对比度弱和高频细节信

基金项目: 国家自然科学基金项目资助(52077078); 国家电网公司科技项目资助(52018K22001P)

息少等缺点, 受限于制造成本及技术水平, 从硬件角度提高传感器的分辨率较难实现^[4-5]。因此, 通过超分辨率重建算法对低精度红外热成像传感器采集到的图像进行清晰化处理, 以提高图像的分辨率, 具有重要的研究价值和广泛的应用前景^[6]。

超分辨率重建技术(super-resolution reconstruction, SR)是将输入的模糊、信息较少的低分辨率图像(low resolution, LR)重建为清晰、信息丰富的高分辨率图像(high resolution, HR), 是计算机视觉领域的一个重要方向^[7-11]。传统的超分辨率重建方法主要分为3类: 基于插值的方法, 如最近邻插值法、双三次插值法等^[12-13]; 基于重建的方法, 如凸集投影法、迭代反投影法和最大后验概率法^[14-16]等; 基于学习的方法, 包括邻域嵌入法、稀疏表示法等^[17-18]。传统的超分算法已经取得了很大的成功, 但是随着对图像轮廓等纹理细节表达能力要求的提高, 传统算法在很大程度上已经无法满足大部分场景的重建效果需求^[19]。

近年来, 随着深度学习与机器视觉技术的快速发展^[20], 众多研究者将深度学习与超分辨率重建相结合。文献[21]将深度学习引入到图像超分辨率领域, 提出了基于卷积神经网络的超分辨率重建模型。文献[22]提出了残差网络, 解决了深层网络带来的梯度和退化问题。文献[23]在网络结构中集成长短跳跃连接和混合注意力机制, 优化了重建图像的边缘和纹理细节。文献[24]将生成对抗网络(generative adversarial network, GAN)应用于图像超分辨率重建领域, 提出了超分辨率生成对抗网络(super-resolution generative adversarial network, SRGAN), 使重建图像的细节更丰富、更具真实感。文献[25]将有效的先验信息引入到神经网络中进行端到端的训练, 重建结果更加自然。文献[26]将边缘注意力机制引入到残差模块中, 并在上采样结构中添加了 1×1 卷积层, 提高了网络的表征能力。然而, 基于卷积或GAN的方法主要针对电力设备的局部特征, 缺乏对全局背景及不同区域之间温度关联性的考虑, 可能使得重建后的电力设备红外图像色彩失真, 无法准确表达设备的温度信息。

Transformer 在计算机视觉领域的逐步应用, 为超分辨率重建提供了新的方法。文献[27]将Transformer 引于计算机视觉领域, 提出了一种用于处理超分辨率、去噪和去雨等多种低级视觉任务的Transformer 模型, 同时解决了长距离依赖的问题。文献[28]针对Transformer 的高计算成本和GPU内存占用大等问题, 提出了一种高效超分辨率

Transformer(efficient super-resolution transformer, ESRT)。然而, 基于Transformer 的方法虽然擅长捕捉图像长距离依赖关系, 但对高频成分不敏感, 在电力设备红外图像超分辨率重建任务中可能存在关键部位模糊、边缘不明显的现象, 影响对潜在异常的判别。

为解决上述问题, 本文兼顾电力设备局部纹理特征和全局温度分布, 提出一种基于Transformer-GAN 聚合网络的超分辨率重建方法。首先, 基于移位卷积设计了电力设备局部特征提取模块, 在不增加参数的情况下扩展卷积的感受野, 提取电力设备的局部纹理特征及其周围不同空间维度特征的信息; 其次, 基于Transformer 构建全局特征提取模块, 并通过深度卷积和空间注意力机制捕捉图像不同区域间温度分布的关联性, 同时使用门控机制构建前馈神经网络, 减少特征通道之间的耦合; 然后, 采用UNet 编解码器网络融合各层局部特征和全局表示, 将局部信息与全局信息频繁交互, 高效地提取电力设备特征; 最后, 使用像素损失、感知损失和对抗损失对模型进行训练, 生成清晰自然的电力设备红外图像。将本文所提基于Transformer-GAN 聚合网络的超分辨率重建方法在电力设备红外热成像数据集上进行实验, 以验证其有效性。

1 Transformer-GAN

本文提出的Transformer-GAN 框架以GAN 为基础, 整个网络结构包括两部分: 生成器和判别器。从局部-全局的角度考虑图像的生成, 更好地学习到复杂的图像特征和结构。其中, 生成器致力于生成与真实数据相似的模拟数据, 而判别器的目标是准确分类模拟数据和真实数据, 以修正生成器的训练方向。通过这种平衡策略, 生成器和判别器相互竞争与协作, 从而训练出高质量的图像^[29]。

2 考虑局部纹理特征和全局温度分布的电力设备红外图像超分辨率重建方法

如图1所示, Transformer-GAN 首先使用低分辨率的电力设备红外图像和真实的高分辨率图像作为生成器的输入, 然后将生成的超分辨率图像和真实的高分辨率图像送入判别器进行判断。经过完整的训练, 当判别器无法正确区分真实数据与模拟数据时, 网络训练结束, 最终完成对低分辨率电力设备红外图像的重建任务。其中, 生成器是一个层次化的编解码器网络, 判别器采用PatchGAN 模型。本文网络结构的具体设计将在后续介绍。

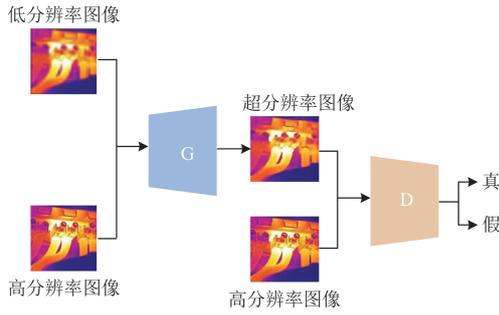


图 1 Transformer-GAN 网络结构图

Fig. 1 Transformer-GAN network structure diagram

2.1 生成器模型

生成器通过学习电力设备的特征生成超分辨率红外图像。本文生成器模型采用 UNet 结构, 包括左侧的特征提取部分(编码阶段)和右侧的特征融合部分(解码阶段), 同时, 在编码阶段和解码阶段之间通过跳跃连接在特征层间传递信息, 以实现足够的特征聚合。为了方便说明, 将 LR、SR 和 HR 分别定义为输入的低分辨率图像、模拟生成的超分辨率图像和真实的高分辨率图像。

1) 编码器: 如图 2 所示, 编码阶段包含 4 层编码器, 每层编码器模型由一个电力设备局部特征提取模块(electrical equipment local feature extraction block, EEFB)、一个全局特征提取模块(global feature extraction block, GFB)和一个下采样块共同组成。下采样块通过步长为 2 的 3×3 卷积层提取电力设备的局部纹理、温度分布等特征信息, 并减小特征映射的尺寸。随后, 使用 LeakyReLU 激活函数来增加模

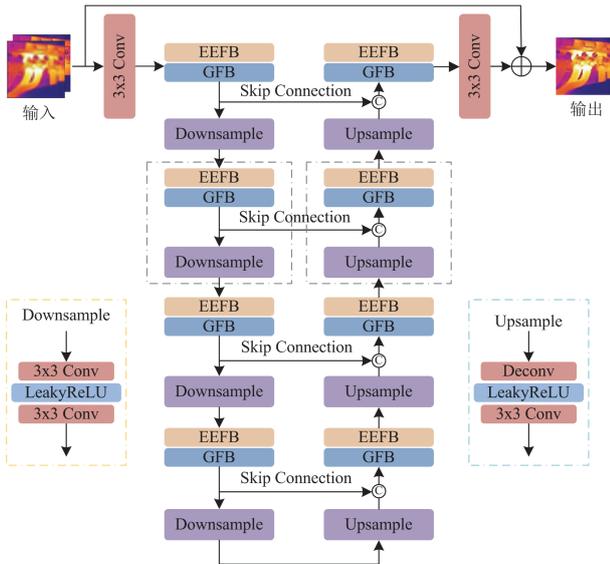


图 2 Transformer-GAN 生成器网络结构图

Fig. 2 Transformer-GAN generator network structure diagram

型的非线性表达能力。最后, 通过一个步长为 1 的 3×3 卷积层对设备关键特征进行过滤和增强。在每层编码器之后, 输出的电力设备红外图像特征映射尺寸减半, 通道数增加一倍。

2) 解码器: 与编码器模型中的下采样块结构不同, 在解码阶段, 上采样块采用一个步长为 2 的 6×6 转置卷积层扩大特征映射的尺寸, 同时提取更多的电力设备特征信息。解码阶段其余网络结构与编码阶段相同。每层解码器将输出的电力设备红外图像特征通道减半, 特征映射的尺寸增加一倍, 逐步恢复设备的边缘纹理细节和全局结构, 从而实现高质量的电力设备红外图像超分辨率重建。

2.1.1 电力设备局部特征提取模块

在电力设备红外图像的超分辨率重建任务中, 捕捉和恢复图像中的纹理细节是关键。红外图像的纹理细节揭示了设备内部的热点, 如连接不良、绝缘损坏、负载不均、局部过热等问题。这些信息对于故障诊断至关重要。同时根据电力设备的裂痕、污秽等局部特征, 可以提前发现设备的老化和磨损迹象, 从而及时实施预防性维护, 延长设备的使用寿命^[30-31]。然而, 由于红外图像的低分辨率和高噪声特性, 难以重建出清晰可辨、特征丰富的电力设备红外图像。因此, 本文设计了电力设备局部特征提取模块(electrical equipment local feature extraction block, EEFB), 使网络结构尽可能地提取有用的信息, 以便更好地恢复图像的清晰度和细节质量。

如图 3 所示, EEFB 主要由移位卷积模块和空间注意力模块组成。其中移位卷积模块由两个移位卷积层和一个 RELU 层组成。移位卷积层通过 1×1 的卷积核和一系列移位操作来捕获电力设备局部特征及其周围不同空间维度特征的信息, 在不增加参数或计算的情况下扩展感受野。随后引入空间注意力模块对输出的特征进一步增强, 帮助网络更好地关注电力红外图像中的重要部分, 如设备的关键区域和潜在的故障点。EEFB 的数学表达式为

$$F' = F + H_{\text{Sconv}}(\text{ReLU}(H_{\text{Sconv}}(F))) \quad (1)$$

$$F'' = H_{\text{conv}}(\text{ReLU}(H_{\text{conv}}(F'))) \quad (2)$$

$$F''' = \text{Sigmoid}(H_{\text{conv}}(F'')) \quad (3)$$

$$F_L = F'' \cdot F''' + F' \quad (4)$$

式中: $H_{\text{Sconv}}(\cdot)$ 表示移位卷积层; $H_{\text{conv}}(\cdot)$ 表示卷积层; $\text{ReLU}(\cdot)$ 表示 ReLU 激活函数; $\text{Sigmoid}(\cdot)$ 表示 Sigmoid 激活函数; F 表示 EEFB 的输入特征; F' 、 F'' 和 F''' 表示 EEFB 的中间特征; F_L 表示 EEFB 的输出特征。

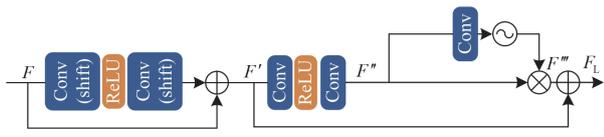


图3 EEFB 结构图

Fig. 3 EEFB structure diagram

2.1.2 全局特征提取模块

如上所述, EEFB 主要用于电力设备局部特征提取, 然而, 由于电力设备红外图像蕴含丰富的热信息, 在重建过程中, 考虑图像空间一致性的同时需要兼顾设备内外部温度场的相互影响, 以便准确地重建图像。CNN 受限于感受野, 无法准确捕捉图像的空间布局及相隔较远区域的温度相关性, 这使

得重建后的设备图像模糊且温度不准确。为了解决这个问题, 本文以 Transformer 为基础, 设计了如图 4(a)所示的全局特征提取模块(global feature extraction block, GFB)。图 4(b)为 GFB 中的深度卷积和空间注意力单元(depthwise convolution and spatial attention unit, DCSU)。沿通道维度将输入的电力设备特征 F_1 等分成两组, 并对每组分别应用 3×3 和 5×5 的深度卷积核, 最终拼接成特征 X 。同时, 引入空间注意力机制充分识别电力设备红外图像的温度分布特点, 得到输出特征 M , 数学表达式为

$$F_1' = H_{\text{conv}}(F_1) \quad (5)$$

$$M = \text{Sigmoid}(H_{\text{conv}}(\text{ReLU}(H_{\text{conv}}(F_1')))) \cdot F_1' + F_1' \quad (6)$$

式中, F_1' 表示 DCSU 的中间特征。

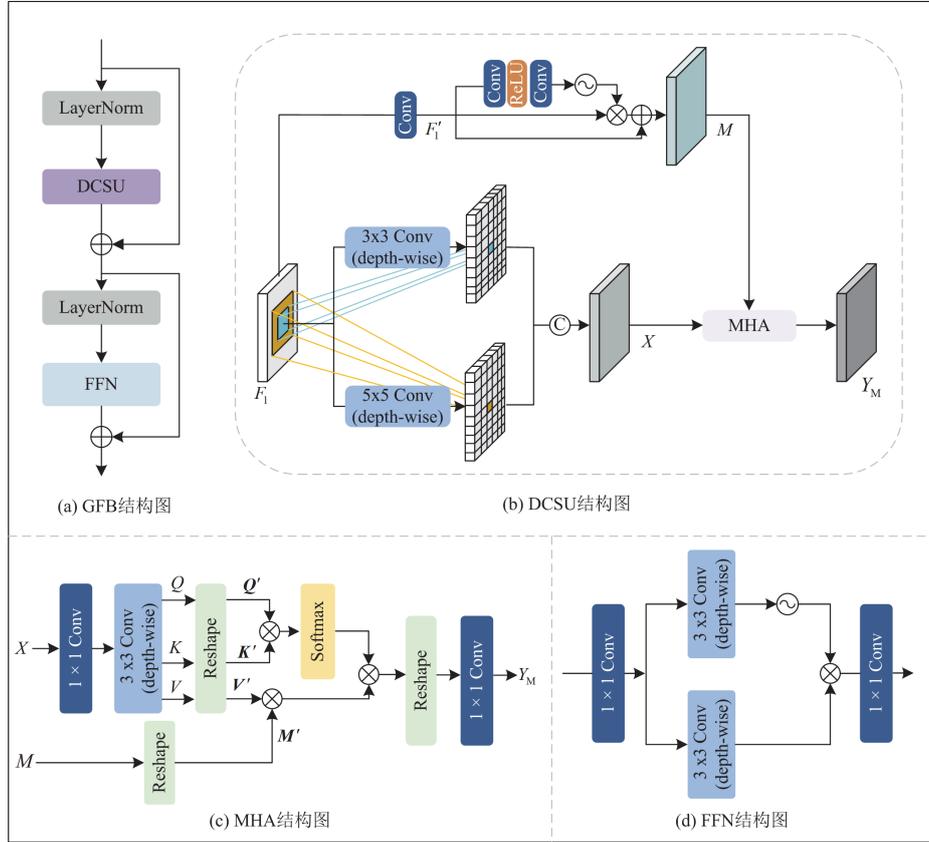


图4 GFB 及其内部模块结构图

Fig. 4 GFB and its internal module structure diagram

将包含设备纹理信息和温度信息的特征 X 和 M 作为多头自注意力(multi-head attention, MHA)的输入, 如图 4(c)所示, 采用 1×1 卷积层和 3×3 深度卷积层对特征 X 进一步特征提取, 然后通过 Reshape 函数进行重构得到查询向量 Q' 、被查询向量 K' 和信息向量 V' , 数学表达式为

$$Q' = \text{Reshape}(H_{\text{Dconv}}(H_{\text{conv}}(X))) \quad (7)$$

$$K' = \text{Reshape}(H_{\text{Dconv}}(H_{\text{conv}}(X))) \quad (8)$$

$$V' = \text{Reshape}(H_{\text{Dconv}}(H_{\text{conv}}(X))) \quad (9)$$

式中: $H_{\text{Dconv}}(\cdot)$ 表示深度卷积层; $\text{Reshape}(\cdot)$ 表示 Reshape 重构函数。

随后, 计算 Q' 和 K' 之间的关联性, 得到不同位置的全局注意力权重矩阵。同时, 对特征 M 进行

重构得到特征矩阵 M' , 并将其与信息向量 V' 相乘, 所得乘积再乘以全局注意力权重矩阵, 从而得到加权的综合电力设备红外图像特征矩阵 X_w 。最后, 将特征矩阵 X_w 重构为特征图, 并采用 1×1 卷积层对其进行过滤和调整, 确保输出能够准确表达设备的边缘纹理和温度特征。数学表达式为

$$X_w = \text{Softmax}(Q' \cdot K' / \sqrt{d}) \cdot (V' \cdot M') \quad (10)$$

$$Y_M = H_{\text{conv}}(\text{Reshape}(X_w)) \quad (11)$$

式中: $\text{Softmax}(\cdot)$ 表示 Softmax 激活函数; Y_M 表示 MHA 的输出特征; d 表示矩阵向量的维度, 是为了避免矩阵点积过大而引入的缩放项。

为了减少特征通道之间的耦合, 本文采用深度卷积和门控机制来构建前馈神经网络(feed-forward network, FFN)。如图 4(d)所示, 特征映射在执行 1×1 的卷积操作后被分成两个平行的分支, 每个路径均通过 3×3 的深度卷积块加强对电力设备局部特征的提取。之后其中一个分支经过 Sigmoid 激活函数后与另一个分支相乘, 最终在 1×1 卷积层进行整合。给定 FFN 的输入特征为 A , 则此过程的数学表达式为

$$A' = H_{\text{Dconv}}(H_{\text{conv}}(A)) \quad (12)$$

$$Y_F = H_{\text{conv}}(A' \cdot \text{Sigmoid}(A')) \quad (13)$$

式中: A' 表示 FFN 的中间特征; Y_F 表示 FFN 的输出特征。

2.2 判别器模型

为了提高判别器的性能和效率, 本文采用文献[32]提出的 PatchGAN 判别器对生成器重建的电力设备红外图像进行真假分类。与传统判别器网络对整张图片进行区分不同, PatchGAN 将输入的热成像图片分割成小块(patch), 对每个小块进行独立判别, 最终求取平均值来预测图像的真实性, 整个判别过程更加高效准确。电力设备红外图像包含复杂的纹理细节, 并且可能存在温度梯度, PatchGAN 在处理这些问题时具有出色的效果和较高的准确性。

2.3 电力设备红外图像损失函数

为保证电力设备红外图像重建的准确性、感官质量和重建图像的真实感, 本文采用的损失函数如下。

1) 像素损失: 像素损失使用 L1 距离来衡量 SR 红外图像和 HR 红外图像像素间的损失。像素损失 L_{pix} 定义为

$$L_{\text{pix}} = \frac{1}{N} \sum_{i=1}^N \|I_{\text{SR}}^i - I_{\text{HR}}^i\|_1 \quad (14)$$

式中: I_{SR}^i 表示生成的第 i 张超分辨率红外图像; I_{HR}^i 表示真实的第 i 张高分辨率红外图像; N 表示用于训练的电力设备红外图像的数量; i 表示图片序号;

$\|\cdot\|_1$ 表示计算的 L1 距离。

2) 感知损失: 感知损失主要用于提高重建 SR 图像的感知质量。具体来说, 使用预先训练的 VGG19 网络从 SR 红外图像和对应的 HR 红外图像中提取特征, 并计算二者特征图之间的 L1 距离, 感知损失 L_{per} 定义为

$$L_{\text{per}} = \frac{1}{N} \sum_{i=1}^N \|\phi(I_{\text{SR}}^i) - \phi(I_{\text{HR}}^i)\|_1 \quad (15)$$

式中, $\phi(\cdot)$ 表示预训练的 VGG19 模型。

3) 对抗损失: 引入对抗性损失是为了生成更清晰和逼真的电力设备红外图像, 对抗损失 L_{adv} 定义为

$$L_{\text{adv}} = -E[\log(D(G(I_{\text{LR}})))] \quad (16)$$

式中: I_{LR} 表示输入的低分辨率红外图像; $G(\cdot)$ 表示生成器模型; $D(\cdot)$ 表示判别器模型; $E[\cdot]$ 表示计算数学期望。最后, 通过最小化总体损失函数来优化 Transformer-GAN, 表示为

$$L_D = -E[\log(D(I_{\text{HR}}))] - E[\log(1 - D(G(I_{\text{LR}})))] \quad (17)$$

$$L_G = \lambda_{\text{pix}} L_{\text{pix}} + \lambda_{\text{per}} L_{\text{per}} + \lambda_{\text{adv}} L_{\text{adv}} \quad (18)$$

式中: L_D 表示判别器的损失函数; L_G 表示生成器的损失函数; λ_{pix} 、 λ_{per} 和 λ_{adv} 表示权重系数, 分别设置为 1、0.01、0.005。

3 算例分析

3.1 实验准备

实验中的数据集为某电力设备红外图像数据集, 共包含避雷器、互感器、变压器、电抗器等 982 张电力设备的热成像图。在模型训练前, 对实验数据集进行预处理, 采用随机旋转 90° 、 180° 、 270° 和水平翻转的方式将数据集扩充至 3000 张, 其中 2400 张作为训练集, 300 张作为测试集, 300 张作为验证集。并根据中心点对图像进行切割, 调整尺寸为 200×200 像素作为 HR 图像, 对 HR 图像进行 4 倍下采样操作得到 LR 图像。实验配置环境如表 1 所示。

表 1 实验配置环境

Table 1 Experimental configuration environment	
配置项	版本
操作系统	Windows11
实验环境	Python3.9
深度学习框架	Pytorch1.13.1
GPU	NVIDIA GeForce RTX 3060
内存	16 G
硬件运行环境	CUDA12.0

为了从不同的角度衡量重建结果与原始高分辨率电力设备红外图像之间的相似度,全面评估重建质量,实验采用峰值信噪比(peak signal-to-noise ratio, PSNR)、结构相似性(structural similarity, SSIM)和视觉信息保真度(visual information fidelity, VIF)作为客观评价指标。PSNR、SSIM 和 VIF 的值越大,重建图像与原始图像之间的差异越小,图像质量越高。

3.2 重建结果分析

实验选取了传统方法 BiCubic 双三次插值法、基于 GAN 的图像重建方法 SRGAN、pix2pix 以及基于 Transformer 图像重建方法的 SwinIR 进行比较,所有模型都使用相同的数据集进行训练。

表 2 为本文方法与其他方法的重建指标对比。由表 2 可以看出 BiCubic 法重建效果最差,这是因为传统的插值法缺乏从数据中学习图像内容的能力。SRGAN 法、pix2pix 法和 SwinIR 法重建效果优于 BiCubic 法,但比 Transformer-GAN 法较差,例如,表 2 中这 3 种方法的 PSNR 比 Bicubic 至少提高了 3.094 dB,SSIM 至少提高了 0.059, VIF 至少提高了 0.066。这些方法有效利用了先验知识,然而未能同时关注设备的边缘纹理和全局信息,导致重建效果仍存在不足。Transformer-GAN 在 PSNR、SSIM 和 VIF 方面较其他方法均呈现出最好的效果。这表明重建后电力设备红外图像与原始图像之间的差异最小,图像质量最佳,充分验证了局部关系和

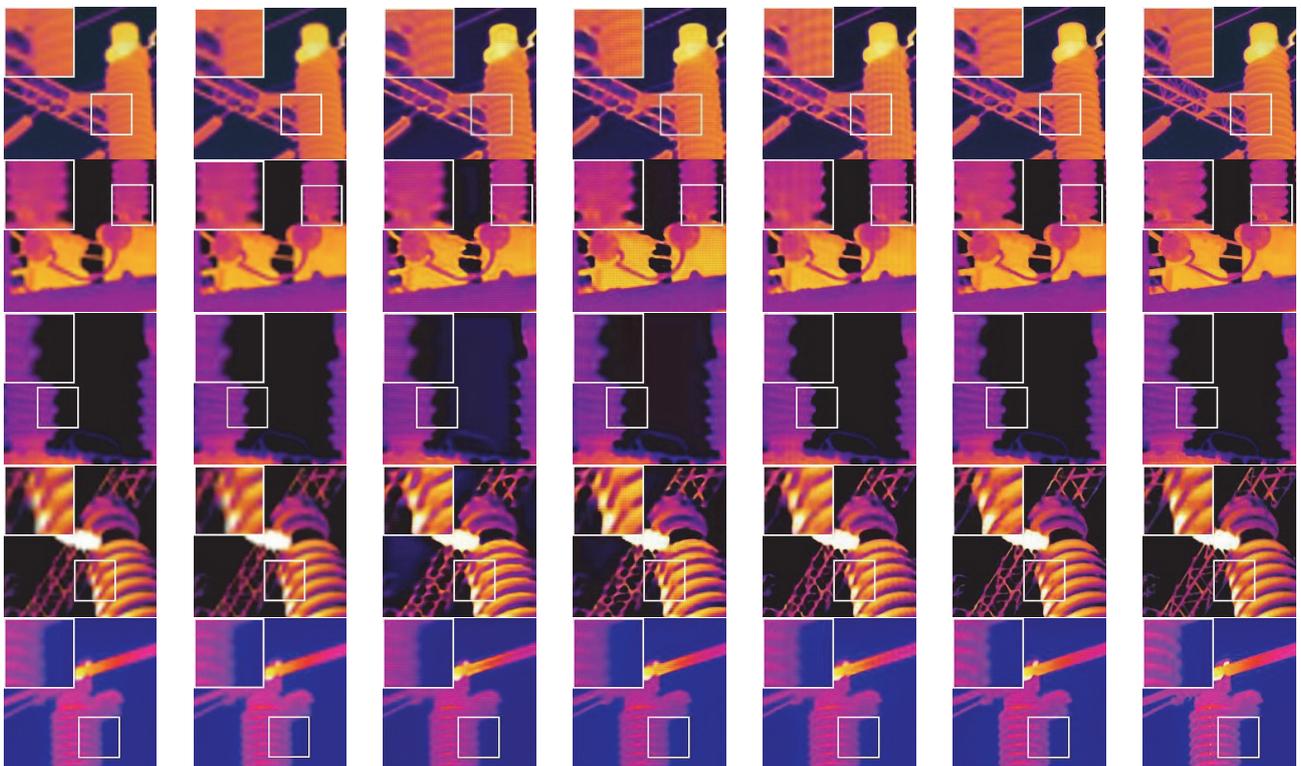
全局关系的结合在处理电力设备红外图像重建任务中的重要性。

表 2 不同方法重建结果

方法	PSNR/dB	SSIM	VIF
BiCubic	24.345	0.693	0.270
SRGAN	27.439	0.752	0.336
pix2pix	28.578	0.782	0.405
SwinIR	29.011	0.816	0.449
Transformer-GAN	29.682	0.847	0.475

同时,将部分电力设备红外图像的重建结果进行展示,每种算法对不同电力设备红外图像的重建效果图如图 5 所示,从左到右依次为低分辨率图像、BiCubic 双三次插值重建图像、SRGAN 重建图像、pix2pix 重建图像、SwinIR 重建图像、Transformer-GAN 重建图像和高分辨率图像,并将重建结果的部分细节放大至图像左上角以便观察。

从图 5 可以看出,各种超分辨率重建方法在一定程度上均可以改善电力设备红外图像的视觉效果和清晰度。BiCubic 法重建后的图像较为模糊,无法有效还原出纹理细节,与低分辨率图像相比在主观视觉方面提升不多;SRGAN 法对背景处理效果不好,部分电力设备红外图像背景颜色发生变化,这说明该方法未能充分捕捉不同区域间的温度关系;pix2pix 法所呈现的电力设备纹理细节比前两种重建



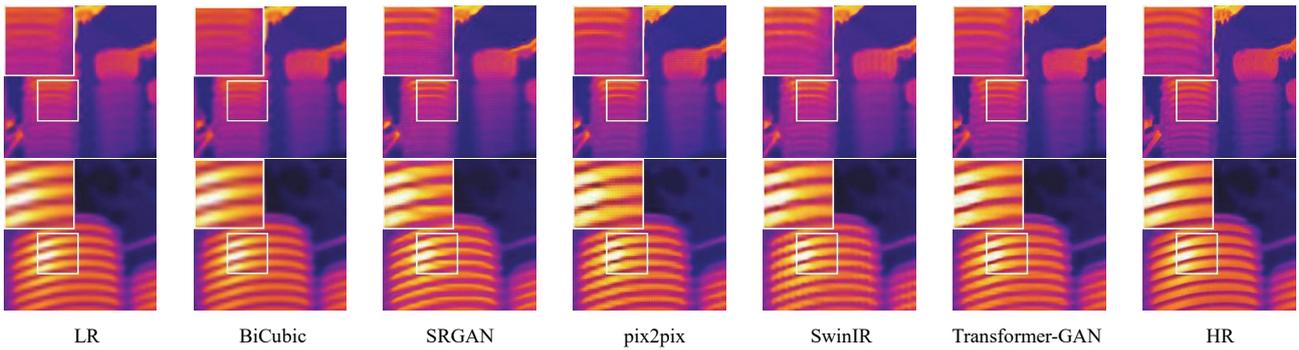


图 5 超分辨率重建结果图

Fig. 5 Super-resolution reconstruction result diagram

结果更清晰自然, 但重建后的图片产生了伪影, 影响视觉效果; SwinIR 法重建的结果改善较好, 但设备边缘线条仍不清晰, 对局部特征的提取不足; 本文方法所呈现的电力设备纹理细节比其他重建结果更清晰自然, 能够有效抑制噪声, 且对于温度的表达更准确, 重建效果最好。

3.3 模型性能分析

1) 训练稳定性分析

通过 TensorBoard 库记录网络在训练过程中每次迭代对应的平均 PSNR、SSIM 以及 VIF 数据, 并使用 Savitzky Golay 滤波器绘制曲线图 6—图 8, 滤波器参数设置为: window_length 为 11、polyorder 为 7。

由图 6—图 8 可以看出, 随着训练的进行, 4 种超分辨率重建模型的平均 PSNR、SSIM 和 VIF 值

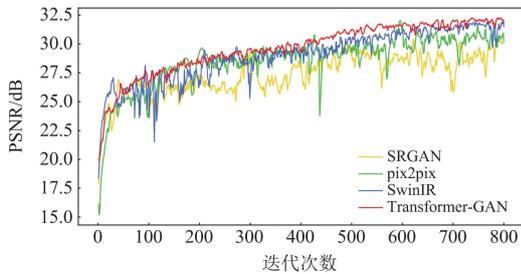


图 6 训练过程 PSNR 迭代曲线

Fig. 6 PSNR iteration curves of training process

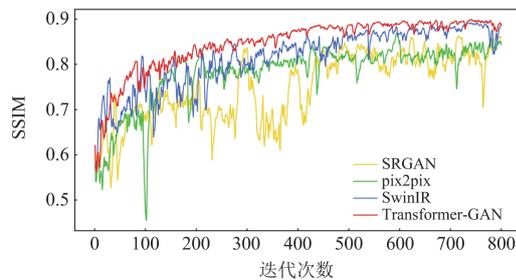


图 7 训练过程 SSIM 迭代曲线

Fig. 7 SSIM iteration curves of training process

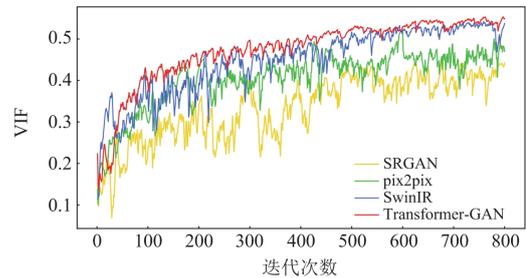


图 8 训练过程 VIF 迭代曲线

Fig. 8 VIF iteration curves of training process

均逐渐升高。然而相比与其他 3 种方法, SRGAN 的模型性能波动相对较大, 尤其是训练前期振荡幅度尤为明显; pix2pix 的稳定性有所改善, 但长期训练中效果依旧不好; SwinIR 在前 300 次迭代的中存在较大幅度的振荡, 经过较多的迭代次数后逐渐趋于稳定; 本文所提 Transformer-GAN 聚合网络在整个训练过程中始终保持稳定的性能, 波动范围更小, 具有更好的重建效果。

2) 重建速度分析

设置算法的学习率和批次大小都相同的情况下, 选取单张电力设备红外图像对不同方法的重建时间进行检验, 测试集每张图片重建所需的平均时间如表 3 所示。

表 3 不同方法重建时间

Table 3 Reconstruction time of different methods

方法	重建时间/ms
SRGAN	1047
pix2pix	1256
SwinIR	761
Transformer-GAN	619

由表 3 可知, 虽然 pix2pix 法重建的效果比 SRGAN 法更好, 但网络计算时间更长; SwinIR 法效率较前两种网络有所提高; Transformer-GAN 法重建耗时为 619 ms, 相比其他模型中最快的 SwinIR

还要快 18.7%，能够高精度高效率地完成电力设备红外图像的重建任务，具有较强的实用性和适应性。

3.4 消融实验

1) EEFB 和 GFB

在 Transformer-GAN 中，EEFB 和 GFB 是网络的最重要组成部分，为了验证二者在电力设备红外图像重建过程中的效果，以及这种组合方法的可行性，本文设计了 3 种模型进行重建，并将各重建结果的客观评价指标进行对比分析，结果如表 4 所示。其中，模型 1 移除了所有的 EEFB，只保留 GFB，标记为“w/o EEFB”。模型 2 移除了所有 GFB，只保留 EEFB，标记为“w/o GFB”。模型 3 为本文所提 Transformer-GAN 聚合网络模型。

表 4 不同模块消融实验结果

Table 4 Results of ablation experiments on different modules

模型	PSNR/dB	SSIM	VIF
w/o EEFB	28.634	0.729	0.409
w/o GFB	28.039	0.772	0.432
Transformer-GAN	29.682	0.847	0.475

由表 4 可知，单独引入 EEFB 或 GFB 均可提高模型的性能，针对电力设备红外图像，无论是设备纹理细节代表的局部特征还是区域间温度相互作用代表的全局关系都有助于图像重建；将 EEFB 和 GFB 二者结合，从而充分兼顾红外特征中的关键细节和整体结构，使得本文所提方法评价指标最高，模型重建效果更优。与只引入 EEFB 相比，PSNR、SSIM 和 VIF 三项指标分别提高了 1.643 dB、0.075 和 0.043；相较于只引入 GFB，三项指标分别提高了 1.048 dB、0.118 和 0.066。

同时，为了突出 EEFB 和 GFB 对图像重建的重要性，采用伪彩逆变换将红外图像转换为灰度图像，之后进行边缘提取操作。重建结果的边缘提取图像如图 9 所示。

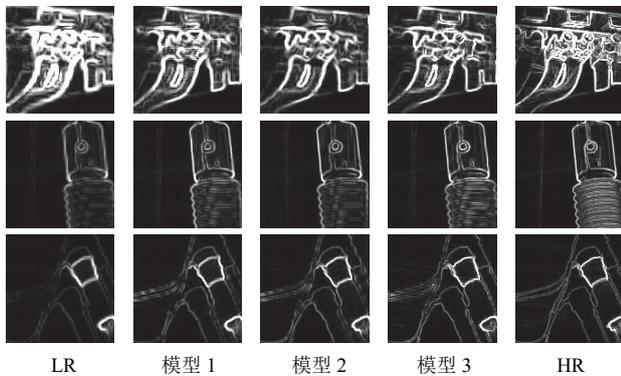


图 9 边缘提取图

Fig. 9 Edge extraction diagram

由图 9 可知，EEFB 和 GFB 均可生成相对清晰的电力设备细节纹理，然而仅使用其中一种并不能实现最优的重建效果，往往会产生许多错误的信息和伪像。而本文方法将 EEFB 和 GFB 结合，兼顾了对电力设备局部特征的表达能力和全局信息的特征提取能力，使得重建后图像边缘轮廓的清晰度得到了提升，细节纹理信息更丰富，进一步验证了所提方法的有效性。

2) 编解码器层数

为了解释选择所提编解码器网络结构的原因，本文分别采用 4 种不同层数的生成器网络进行电力设备红外图像重建。分别设置为 3 层、4 层、5 层、6 层。重建结果如表 5 所示。

表 5 不同编解码器层数消融实验结果

Table 5 Results of ablation experiments with different levels of encoder/decoder

层数	PSNR/dB	SSIM	VIF
3	28.345	0.796	0.415
4	29.682	0.847	0.475
5	29.251	0.819	0.446
6	28.245	0.773	0.401

由表 5 可知，3 层编解码器模型在生成图像时存在明显的内容损失和颜色失真。4 层编解码器结构，相较于 3 层，网络的性能有了显著提升。然而，当增加到 5 层时，与 4 层相比，性能有所下降，这是因为电力设备红外图像的多样性有限，且图像之间存在相似性，过多的网络层数导致在训练数据上过度拟合，从而影响了模型的训练效果。此外，6 层的编解码器结构相较于 5 层，性能显著降低，泛化性进一步减弱，这表明适当层数的编解码器对于保持模型性能的重要性。根据表 5 中的评估指标，本文方法能够实现最佳的重建效果。

3.5 验证实验

为了评估本文方法在工程中的实用性，选取缺乏高分辨率原图的电缆接头红外图像进行超分辨率重建，图 10 为对电缆接头红外图像进行超分辨率重建前后的对比图。

如图 10 所示，原始图像由于缺乏高分辨率细节，显得较为模糊，而经过超分辨率重建后的接头处边缘轮廓更加锐利，清晰地展示了接头的热分布特征，对于检测潜在的热点、分析接头的老化状况以及预测可能的故障点至关重要。实验表明，本文方法可以在传感器像素采样精度有限情况下，真实地还原电力设备图像的细节特征，从算法的角度提高电力设备红外图像的分辨率，有效降低了在电力

设备红外监测应用场景中的成本投入, 具有较高的应用价值。

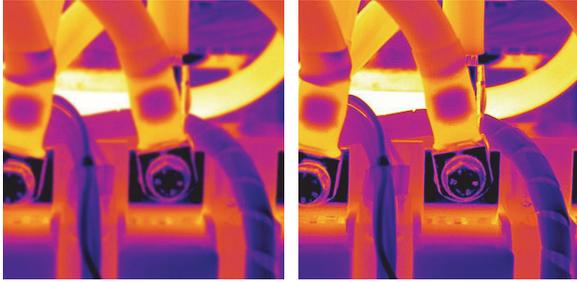


图 10 电缆接头重建前后对比图

Fig. 10 Comparison before and after cable joint reconstruction

4 结论

针对电力设备红外图像分辨率较低的问题, 本文考虑将电力设备局部纹理特征和全局温度分布充分结合, 提出了基于 Transformer-GAN 聚合网络的超分辨率重建方法, 并通过某电力设备红外热成像数据集验证了所提方法的有效性, 结论如下。

1) 所提方法基于移位卷积设计了电力设备局部特征提取模块, 捕捉电力设备红外图像中的纹理细节, 重建后的图像边缘轮廓清晰, 纹理信息丰富。

2) 所提方法通过深度卷积和空间注意力机制构建了全局特征提取模块, 识别电力设备的整体布局 and 结构, 关注图像内不同区域之间温度的相关性, 重建图像能够准确反映电力设备的热特性。

3) 所提方法与其他方法相比, 客观评价指标 PSNR、SSIM、VIF 分别为 29.682 dB、0.847 和 0.475, 均为最优, 主观视觉质量也有明显改善, 同时具有良好的训练稳定性和更快的重建速度。在无高分辨率原图的情况下, 能够生成清晰自然的电力设备红外图像, 有利于运维人员据此准确掌握电力设备运行状态, 对于电力系统的故障诊断和状态监测具有重要意义。

参考文献

[1] 刘东超, 陈志刚, 崔龙飞. 基于物联网的环网柜在线监测技术研究[J]. 电力系统保护与控制, 2022, 50(20): 60-67.
LIU Dongchao, CHEN Zhigang, CUI Longfei. Online monitoring technology of a ring network cabinet based on the internet of things[J]. Power System Protection and Control, 2022, 50(20): 60-67.

[2] 李宏川, 赵宇, 李彬, 等. 配电物联网边缘计算场景下基于改进 ANFIS 的电缆通道综合评估及智能预警方法研究[J]. 电力系统保护与控制, 2024, 52(12): 94-103.

LI Hongchuan, ZHAO Yu, LI Bin, et al. Comprehensive assessment and intelligent early warning of cable passages based on improved ANFIS in the edge computing scenario of PDIoT[J]. Power System Protection and Control, 2024, 52(12): 94-103.

[3] 刘建峰, 李志远, 周亚茹. 基于漏磁场和 ICOA-ResNet 的变压器绕组早期故障诊断[J]. 电力系统保护与控制, 2024, 52(9): 99-110.
LIU Jianfeng, LI Zhiyuan, ZHOU Yaru. Transformer windings based on leakage field and ICOA-ResNet early fault diagnosis[J]. Power System Protection and Control, 2024, 52(9): 99-110.

[4] 赵洪山, 刘秉聪, 王龄婕, 等. 基于压缩感知的电力设备红外图像盲超分辨率方法[J]. 电网技术, 2022, 46(3): 1177-1187.
ZHAO Hongshan, LIU Bingcong, WANG Lingjie, et al. Blind super resolution for infrared image of power equipment based on compressed sensing[J]. Power System Technology, 2022, 46(3): 1177-1187.

[5] 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.

[6] 刘云峰, 杨晋彪, 韩晋锋, 等. 基于边缘增强生成对抗网络的电力设备热成像超分辨率重建[J]. 电力建设, 2021, 42(7): 83-89.
LIU Yunfeng, YANG Jinbiao, HAN Jinfeng, et al. Super-resolution reconstruction of thermal imaging of power equipment based on edge-enhancement generative adversarial network[J]. Electric Power Construction, 2021, 42(7): 83-89.

[7] 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): 181-187.
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): 181-187.

[8] 袁茜琳, 张宝辉, 张倩, 等. 基于深度卷积神经网络的红外图像超分辨率重建技术[J]. 红外技术, 2023, 45(5): 498-505.
YUAN Xilin, ZHANG Baohui, ZHANG Qian, et al. Infrared images with super-resolution based on deep

- convolutional neural network[J]. *Infrared Technology*, 2023, 45(5): 498-505.
- [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): 7990-7998.
- 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): 7990-7998.
- [10] 程德强, 袁航, 钱建生, 等. 基于深层特征差异性网络的图像超分辨率算法[J]. *电子与信息学报*, 2024, 46(3): 1033-1042.
- CHENG Deqiang, YUAN Hang, QIAN Jiansheng, et al. Image super-resolution algorithms based on deep feature differentiation network[J]. *Journal of Electronics & Information Technology*, 2024, 46(3): 1033-1042.
- [11] 郭宇烽, 金尚忠, 李宏光, 等. 基于线阵扫描成像的太赫兹图像超分辨率重建[J]. *中国激光*, 2024, 51(8): 283-290.
- GUO Yufeng, JIN Shangzhong, LI Hongguang, et al. Super-resolution reconstruction of terahertz image based on linear array scanning imaging[J]. *Chinese Journal of Lasers*, 2024, 51(8): 283-290.
- [12] SUN Na, LI Huina. Super resolution reconstruction of images based on interpolation and full convolutional neural network and application in medical fields[J]. *IEEE Access*, 2019, 7: 186470-186479.
- [13] SONG Huihui, XU Wenjie, LIU Dong, et al. Multi-stage feature fusion network for video super-resolution[J]. *IEEE Transactions on Image Processing*, 2021, 30: 2923-2934.
- [14] YANG Jianchao, WRIGHT J, HUANG T, et al. Image super-resolution as sparse representation of raw image patches[C] // 2008 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2008, Anchorage, AK, USA: 1-8.
- [15] 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.
- [16] YANG Wenming, ZHANG Xuechen, TIAN Yapeng, et al. Deep learning for single image super-resolution: a brief review[J]. *IEEE Transactions on Multimedia*, 2019, 21(12): 3106-3121.
- [17] 丁玉祥, 卞维新, 接标, 等. 融合邻域回归和稀疏表示的图像超分辨率重构[J]. *计算机工程与应用*, 2021, 57(2): 230-236.
- DING Yuxiang, BIAN Weixin, JIE Biao, et al. Super-resolution image reconstruction based on neighborhood regression and sparse representation[J]. *Computer Engineering and Applications*, 2021, 57(2): 230-236.
- [18] XIE Chao, LU Xiaobo, ZENG Weili. Single frame super-resolution reconstruction based on sparse representation[J]. *Journal of Southeast University*, 2016, 32(2): 177-182.
- [19] 吴靖, 叶晓晶, 黄峰, 等. 基于深度学习的单帧图像超分辨率重建综述[J]. *电子学报*, 2022, 50(9): 2265-2294.
- WU Jing, YE Xiaojing, HUANG Feng, et al. A review of single image super-resolution reconstruction based on deep learning[J]. *Acta Electronica Sinica*, 2022, 50(9): 2265-2294.
- [20] 付添, 邓长征, 韩欣月, 等. 基于深度学习的电力设备红外与可见光图像配准[J]. *红外技术*, 2022, 44(9): 936-943.
- FU Tian, DENG Changzheng, HAN Xinyue, et al. Infrared and visible image registration for power equipments based on deep learning[J]. *Infrared Technology*, 2022, 44(9): 936-943.
- [21] DONG Chao, LOY C C, HE Kaiming, et al. Learning a deep convolutional network for image super-resolution[C] // *Computer Vision-ECCV2014*, September 6-12, 2014, Zurich, Switzerland: 184-199.
- [22] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. deep residual learning for image recognition[C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA: 770-778.
- [23] 卢正浩, 刘丛. 多尺度特征复用混合注意力网络的图像重建[J]. *中国图象图形学报*, 2021, 26(11): 2645-2658.
- LU Zhenghao, LIU Cong. Multiscale feature reuse mixed attention network for image reconstruction[J]. *Journal of Image and Graphics*, 2021, 26(11): 2645-2658.
- [24] LEDIG C, THEIS L, HUSZÁR 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: 105-114.
- [25] WANG Xintao, YU Ke, DONG Chao, et al. Recovering realistic texture in image super-resolution by deep spatial feature transform[C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA: 606-615.

- [26] 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): 3564-3573.
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): 3564-3573.
- [27] CHEN Hanting, WANG Yunhe, GUO Tianyu, et al. Pre-trained image processing transformer[C] // 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 20-25, 2021, Nashville, TN, USA: 12294-12305.
- [28] LU Zhisheng, LI Juncheng, LIU Hong, et al. Transformer for single image super-resolution[C] // 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), June 19-20, 2022, New Orleans, LA, USA: 456-465.
- [29] 王艳, 连洪钵, 王寅初, 等. 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[J]. 电力系统保护与控制, 2024, 52(3): 119-127.
WANG Yan, LIAN Hongbo, WANG Yinchu, et al. Super-resolution reconstruction of thermal imaging of power equipment based on improved edge-attentive generative adversarial networks[J]. Power System Protection and Control, 2024, 52(3): 119-127.
- [30] 陈伟, 孙存育, 裴婷婷, 等. 计及劣化状态和随机故障的光伏发电系统视情维修模型以及最优检修策略[J]. 电力系统保护与控制, 2024, 52(12): 154-166.
CHEN Wei, SUN Cunyu, PEI Tingting, et al. Condition-based maintenance model and optimal maintenance strategy of a photovoltaic power generation system considering deterioration state and random failure[J]. Power System Protection and Control, 2024, 52(12): 154-166.
- [31] 张春晓, 陆志浩, 刘相财. 智慧变电站联合巡检技术及其应用[J]. 电力系统保护与控制, 2021, 49(9): 158-164.
ZHANG Chunxiao, LU Zhihao, LIU Xiangcai. Joint inspection technology and its application in a smart substation[J]. Power System Protection and Control, 2021, 49(9): 158-164.
- [32] ISOLA P, ZHU Junyan, ZHOU Tinghui, et al. Image-to-image translation with conditional adversarial networks[C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA: 5967-5976.

收稿日期: 2024-06-15; 修回日期: 2024-07-24

作者简介:

赵洪山(1965—), 男, 博士生导师, 教授, 研究方向为电力系统运行与控制、电力设备故障预测与优化运维等;
E-mail: zhaohshcn@ncepu.edu.cn

王惠东(1999—), 男, 硕士研究生, 研究方向为电力设备红外图像超分辨率重建、电力设备红外图像分割等。
E-mail: 992321039@qq.com

(编辑 许威)