

基于WGAN图片去模糊的绝缘子目标检测

王德文^{1,2}, 李业东^{1,2}

(1. 华北电力大学 控制与计算机工程学院, 河北 保定 071003;

2. 复杂能源系统智能计算教育部工程研究中心, 河北 保定 071003)

摘要:针对不可抗力因素造成无人机航拍绝缘子图片模糊、绝缘子目标检测率较低的问题,提出了一种基于Wasserstein距离优化的生成式对抗网络(WGAN)图片去模糊的绝缘子目标检测方法。首先在WGAN训练过程中引入残差网络,使得生成的绝缘子图片更加清晰;其次在损失函数中引入Wasserstein距离以保证训练过程的稳定性;最后通过优化模型的训练过程,使得生成的绝缘子图片细节还原度更高。绝缘子图片去模糊化实验结果表明,所提方法在结构相似性与峰值信噪比等评价指标上均高于基于卷积神经网络与深度多尺度卷积神经网络等图像去模糊算法。另外,将利用所提方法生成的绝缘子图片与模糊绝缘子图片划分为3组,采用改进的基于区域建议的卷积神经网络目标检测算法分别进行目标检测实验,精确度均值分别提高了5.77%、6.73%与5.98%,有效提高了绝缘子的目标检测率。

关键词:绝缘子;目标检测;Wasserstein距离优化的生成式对抗网络;去模糊;残差网络

中图分类号:TM 855

文献标志码:A

DOI:10.16081/j.epae.202003020

0 引言

绝缘子作为电力输电线路非常重要的绝缘器件,其运行状况直接影响到电网的可靠性和安全性^[1-2]。据可靠统计,电力系统故障中所占比例最高的事故是由绝缘子受损引起的,所以对绝缘子的状况进行监测并及时完成故障诊断具有重要的意义^[3]。绝缘子目标检测是绝缘子故障诊断的基础^[4],若绝缘子的目标检测率较低或者漏检,则后续的绝缘子故障诊断也将无法顺利进行,因此提高绝缘子的目标检测率具有重要的实际意义^[5]。

目前,通过深度学习对绝缘子图片进行目标检测已经成为了一个热门的研究问题,研究内容主要包括基于候选区域和基于回归的图像识别算法等。

(1)基于候选区域的图像识别算法,如基于区域建议的卷积神经网络(R-CNN)、特征金字塔网络(FPN)和改进的基于区域建议的卷积神经网络(Faster-RCNN)等是通过先确定候选区域再对目标进行识别,这类方法识别复杂背景下的绝缘子效果较好,但是网络训练过程较为繁琐,过程参数相对较多,识别效果依赖于候选区域的选择,如文献[6]利用卷积神经网络先对绝缘子进行粗定位,再对绝缘子进行识别,该方法在目标检测过程中表现比较稳定,但是受限于第一步粗定位的定位结果,在粗定位误差较大时,无法准确地检测到绝缘子;文献[7]则是基于改进的卷积神经网络对绝缘子进行目标检

测,缩小绝缘子的候选区域,从而提高了复杂背景图像中的绝缘子目标检测率,但在实际情况中,由于光线等原因会导致绝缘子色差不同,部分绝缘子目标可能会被当成背景分离掉从而导致目标检测率下降。

(2)基于回归的图像识别算法,如YOLO2v2、YOLOv3和单次多目标检测识别(SSD)算法等直接检测图像的目标,这类方法过程参数较少,检测速度较快,但是对于复杂背景中的绝缘子漏检率较高。如文献[8]提出了一种基于SSD的绝缘子检测方法,有效地提高了检测过程中模型的鲁棒性;文献[9]提出了一种YOLOv2算法和图像处理结合的绝缘子目标检测方法,该方法检测速度快,检测率也更高。

上述基于候选区域和基于回归的图像识别算法虽然能够有效快速地识别绝缘子的位置,但是当绝缘子位置较密集或背景过于复杂时,易发生漏检。

航拍无人机在执行航拍绝缘子任务的过程中,可能会因为天气、数据处理、相机自身和地物环境等原因导致采集到的绝缘子图片模糊。利用常规目标检测算法直接对模糊绝缘子图片进行目标检测时,其目标检测率可能会下降甚至会出现漏检的情况。生成式对抗网络(GAN)是近年来备受关注的生成式模型,它能够通过神经网络的训练以无监督的形式自动学习绝缘子图片的特征分布,进而生成清晰的绝缘子图片,对解决上述问题有重要的意义。

GAN由生成器网络和判别器网络构成,采用相互对抗的形式进行训练,相互提高各自的生成能力和判别能力,最终生成器将学习到数据样本的潜在规律,能够生成以假乱真的数据样本,在图像和计算机视觉领域得到了广泛应用^[10]。文献[11]利用条件卷积GAN图像识别方法降低了对样本数据的依

收稿日期:2019-07-03;修回日期:2020-01-17

基金项目:国家自然科学基金资助项目(51677072)

Project supported by the National Natural Science Foundation of China(51677072)

赖,文献[12]利用超分辨率GAN(SRGAN)对图像进行数据重建,从而提高了图像的分辨率。但是正如文献[13]中所述,传统的GAN在训练过程中受到目标函数的限制,极易出现模式崩溃的问题,所以本文采用 Wasserstein 距离代替 JS 散度(Jensen Shannon divergence)训练GAN,通过最小化 Wasserstein 距离来提高GAN在训练中的稳定性。

在GAN生成样本的过程中,在一定程度上随着网络结构的加深,提取到的特征就越丰富,越具有语义信息,生成的样本精度也越高,但是在实际应用中,网络深度虽然加深了,但是生成的样本质量却没有提升甚至出现了下降的信息^[14]。通过在生成器中引入残差网络,利用跳跃式的连接可避免这一问题,使得生成的样本更加逼真。

本文根据模糊绝缘子图片的特征设计了一种基于 Wasserstein 距离和残差网络的GAN,通过 Wasserstein 距离约束生成损失,利用多层连续的残差网络保证生成图像的清晰度。将绝缘子的模糊图片作为生成器的输入,通过生成器生成图片后,由判别器判别该图片的真实来源,然后将判别结果返回到生成器中,生成器根据反馈继续学习绝缘子图片特征,判别器则根据反馈继续提高自身的判别能力,通过生成器和判别器的来回博弈,最终由生成器生成清晰的绝缘子图片,并利用 Faster-RCNN 目标检测算法对生成的绝缘子图片进行目标检测。

1 生成对抗

1.1 GAN 理论分析

GAN由生成器和判别器构成,其结构如图1所示。图中, $G(z)$ 为生成样本。

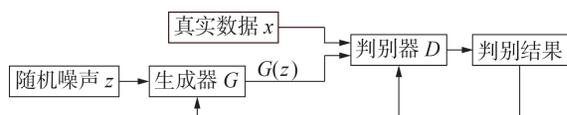


图1 GAN 结构

Fig.1 Structure of GAN

设随机噪声 z 为一组服从 $P_z(z)$ 分布(例如高斯分布、均匀分布等)的数据,即 $z \sim P_z(z)$,原始数据 x 为服从 $P_{\text{data}}(x)$ 的一组数据,即 $x \sim P_{\text{data}}(x)$,则GAN的目标函数如下:

$$\min_G \max_D V(D, G) = E_{x \sim P_{\text{data}}(x)} [\log_a D(x)] + E_{z \sim P_z(z)} [\log_a (1 - D(G(z)))] \quad (1)$$

其中, $E[\cdot]$ 表示期望运算; a 为常数,在实验中常取2或者e。在GAN训练的过程中,保持生成器 G 不变,优化判别器 D ,使 D 的判别概率最大化;然后在此基础上,保持判别器 D 不变,继而优化生成器 G ,使得 D 的判别概率最小化。当生成器生成数据和原始数据

分布相同时,达到全局最优解。

1.2 WGAN

GAN是基于JS散度和KL散度(Kullback Leibler divergence)进行优化的,该种优化方式会出现梯度消失和模型崩溃的问题^[14],因此本文提出一种基于 Wasserstein 距离优化的GAN(WGAN)。

Wasserstein 距离的定义如下:

$$W(P_r, P_g) = \inf_{\gamma \in \Omega(P_r, P_g)} E_{(x,y) \sim \gamma} [\|x - y\|] \quad (2)$$

其中, \inf 表示取下确界; $\Omega(P_r, P_g)$ 为分布 P_r 和 P_g 组合而成的所有可能的联合分布的集合。对于每一个可能的联合分布 γ 而言,可以从中采样 $(x, y) \sim \gamma$ 获得一个真实样本 x 和一个生成样本 y ,这对样本的距离 $\|x - y\|$ 的期望值即为 Wasserstein 距离。

相较于GAN,WGAN使用 Wasserstein 距离度量真实样本和生成样本间的距离,其具有如下优点:

(1)训练过程中,即使生成样本和真实样本没有重叠,Wasserstein 距离仍能计算出2种样本的差异;

(2)拥有优越的平滑特性,可以解决GAN训练过程中梯度消失的问题;

(3)WGAN无需担心平衡生成器和判别器的训练程度,解决了训练不稳定的问题,同时生成的样本具有多样性;

(4)在训练过程中可以设定一个类似交叉熵、错误率的数值来指示训练的过程,该数值越小代表WGAN训练得越好,生成器生成的图片质量也越高。

1.3 残差网络

在模型训练的过程中,假设该部分神经网络的输入为 x ,输出函数映射为 $H(x)$,则整个恒等映射过程为:

$$x = H(x) \quad (3)$$

反向传播过程中,映射的变化率为:

$$p = (H(x) - x) / x \quad (4)$$

但是在训练后期,图片质量的提升逐渐变小, p 的值会随着训练逐渐变小,导致反馈过程中映射对输出变化变得不敏感,从而引起梯度消失的问题,后续生成的图片质量也不再提高,甚至出现退化问题。

为了解决该问题,在训练过程中引入残差网络,设 $F(x) = H(x) - x$,则整个映射变为:

$$H(x) = F(x) + x \quad (5)$$

在 p 值过小的情况下,计算每次 $F(x)$ 的变化率,即:

$$q = (F(x_1) - F(x)) / F(x) \quad (6)$$

其中, x_1 为下一次模型输出。

将 q 代替 p 反馈到神经网络中,提高模型对输出变化的敏感性,解决模型训练过程中梯度消失的问题,残差网络结构如图2所示。

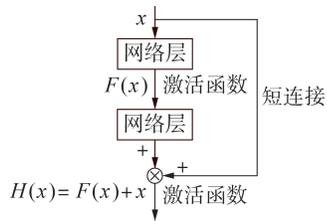


图2 残差网络结构

Fig.2 Structure of residual network

2 基于WGAN图片去模糊的绝缘子目标检测

2.1 绝缘子目标检测

绝缘子目标检测的目的是从不同复杂程度的背景中辨识出绝缘子,并分离背景,从而完成故障排查和检修等后续任务。绝缘子目标检测是绝缘子故障诊断的基础任务,其检测率的高低将直接影响后续的故障排查^[15]。利用目标检测算法对绝缘子图像进行绝缘子目标检测的基本流程见附录中的图A1。

无人机执行采集绝缘子图片任务的过程中,会因为不可抗力的因素导致采集到的绝缘子图片比较模糊,其原因主要包括4类^[16]:在强风和降雨的情况下,无人机飞行姿态不稳定会导致拍摄的绝缘子图片模糊;GPS信号差的情况下,无人机定位信息浮动较大,短时间内大范围地修正定位会导致拍摄的绝缘子图片模糊;无人机拍摄时镜头的焦距等参数设定不正确造成采集的绝缘子图片模糊;大部分高压线路都位于野外地区,无人机在拍摄时光线和地势起伏变化比较大,导致无人机上的相机无法精确对焦,从而造成绝缘子处在焦点外的模糊情况。直接利用常用目标检测算法对模糊绝缘子图片进行目标检测时,其目标检测率可能会下降且极易出现漏检。

2.2 基于WGAN的模糊绝缘子图片识别模型

针对上述问题,本文提出了基于WGAN图片去模糊的绝缘子目标检测方法并设计了模糊绝缘子图片检测BIID(Blur Insulator Image Detection)模型,见附录中的图A2。BIID模型主要包括4个阶段。

(1)数据集构造阶段:构造绝缘子图片数据集。

(2)网络构造阶段:针对模糊绝缘子图像数据集,基于残差网络和Wasserstein距离构造模糊绝缘子图片去模糊网络WGAN(BIID-WGAN)。

(3)网络训练阶段:利用数据集训练BIID-WGAN,训练结束后,利用该网络生成清晰绝缘子图片。

(4)结果测试阶段:将本文方法与传统去模糊算法进行比较,然后利用目标检测算法对未处理的绝缘子图片和去模糊化的绝缘子图片进行绝缘子目标识别,得到识别结果并对其进行对比分析。

2.3 BIID-WGAN的构造

BIID-WGAN由生成器和判别器构成,通过生成器和判别器的来回博弈,最终由生成器生成清晰绝缘子图片。

2.3.1 BIID-WGAN网络生成器结构

针对绝缘子模糊图像的多样性和复杂性,在生成器中引入残差模块。残差模块相对于标准的卷积模块在反向传播中对输出的变化更敏感,可以更细微地调整权重,生成的绝缘子图片细节还原度更高。生成器由上采样块、残差网络块和下采样块共同组成,其网络结构见附录中的图A3。

(1)在下采样块中,以 $256 \times 256 \times 3$ 维的绝缘子模糊图像作为生成器的输入,为了使数据维度变得可填充、可扩展,且在后续的变换过程中不会丢失绝缘子的特征信息,利用反射填充(ReflectionPadding2D)对输入进行处理,之后再对数据进行卷积操作,通过连续3层的卷积操作(Conv2D)将数据变换成 $64 \times 64 \times 256$ 维的特征映射,在输入残差网络块前再通过激活函数Relu对数据进行非线性激活,残差网络块采用Dropout函数作为拟合函数。

(2)在深度神经网络训练中,随着训练和网络层数的增加,模型将出现退化等问题。所以在生成器中引入残差网络,采用短连接(shortcut connection)方式,该连接方式只执行同等映射,不会产生额外的参数,也不会增加计算复杂度,其结构如图3所示。

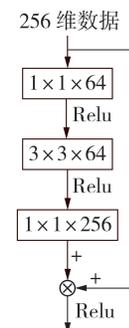


图3 残差网络的短连接

Fig.3 Shortcut connection of residual network

在残差网络块中,为了防止在训练过程中出现拟合,每一次对数据进行卷积之后均添加概率为0.5的丢失正则化函数。

(3)在上采样块(UPSampling2D)中,首先对下采样块中的特征映射进行解卷积操作,通过解卷积层和卷积层之后,再次将数据维度变换为 $256 \times 256 \times 3$ 。为了防止采样的误差过大,在采样结束后,再通过激活函数在生成器的输入和输出增加一个连接,将数据批量归一化BN(Batch-Normalization),使得输入和输出均为 $256 \times 256 \times 3$ 维的图像数据。

2.3.2 BIID-WGAN判别器结构

为了判别输入的绝缘子图像的真实来源,设计判别器结构如附录中的图A4所示。

判别器的输入可能是真实数据 x ,也可能是生成器生成的数据 $G(z)$,当输入真实数据 x 时,判别器的正确输出为1,当输入 $G(z)$ 时,判别器的正确输出为

0。判别器中共包括5个卷积层,为了增强神经网络各层之间的非线性关系,减少梯度消失的情况,在所有卷积层中使用Leaky-Relu(LR)非线性激活函数,并使用BN做批量归一化处理。

2.3.3 BIID-WGAN 损失函数

由于绝缘子图片的复杂性和多样性,为了提升BIID-WGAN训练的稳定性和高效性,本文分别在BIID-WGAN的判别器末尾和整个BIID-WGAN的末尾这2个层面提取损失。在判别器末尾,计算生成器生成的图片和原始清晰图片之间的Wasserstein距离,相对于GAN默认的损失函数,在保证不会发生梯度消失的情况下,Wasserstein距离能够使模型收敛得更快。在BIID-WGAN的末尾,采用感知损失^[17]和上述Wasserstein损失函数的结合作为模型的损失函数。损失函数和感知损失的定义分别为:

$$\mathcal{L} = \mathcal{L}_w + \lambda \mathcal{L}_x \quad (7)$$

$$\mathcal{L}_x = \frac{1}{W_{ij} H_{ij}} \sum_{k=1}^{W_{ij}} \sum_{b=1}^{H_{ij}} \left(\phi_{i,j}(I^S)_{k,b} - \phi_{i,j}(G_\theta(I^B))_{k,b} \right)^2 \quad (8)$$

其中, \mathcal{L}_w 为Wasserstein损失, \mathcal{L}_x 为感知损失, λ 为为了平衡这2个目标函数引入的超参数,实验中通常取为100^[18]; I^S 为生成的清晰图像; I^B 为模糊图像; G_θ 为生成器; $\phi_{i,j}$ 表示在Imagenet^[19]上预训练的VGG19网络内的第*i*个最大化层之前通过第*j*个卷积层(激活之后)获得的特征图, W_{ij} 和 H_{ij} 分别为该特征图的宽度和高度。

3 BIID-WGAN 训练

BIID-WGAN训练使用SGD优化函数进行梯度下降,初始学习率设定为 e^{-4} ,在训练200次后开始逐渐下降,Batch尺寸设置为16,生成器与判别器的训练比值为4:1^[20-22]。

生成器训练过程见附录中的图A5,其主要通过以下2个反馈调整权重:

(1)通过比较生成器生成的绝缘子图片 $G(z)$ 和原始清晰绝缘子图片 x 之间的差值,计算两者之间的Wasserstein距离,通过该距离调整权重;

(2)将生成器生成的绝缘子图像 $G(z)$ 和原始清晰绝缘子图像 x 输出到判别器中,根据判别器的结果 $D(G(z), x)$ 与1之间的差值对生成器的权重进行进一步的调整。

判别器训练过程见附录中的图A6,其通过以下2种途径调整权重:

(1)输入模糊绝缘子图片和清晰绝缘子图片,通过比较判别器输出的值 $D(z, x)$ 与标准值1的差值,进而调整训练器权重;

(2)将生成器生成的绝缘子图像 $G(z)$ 和原始清晰绝缘子图像 x 输出到判别器中,根据判别器的结果 $D(G(z), x)$ 与0的差值进一步调整判别器的权重。

4 实验结果及分析

4.1 实验环境及参数设定

实验环境:CPU为i7-8700,显卡为1080ti(11 GByte),内存容量为32 GByte,操作系统为Ubuntu 14.04.3,开发环境为Python+keras(TensorFlow)。

数据集一共包括了5000对清晰-模糊的绝缘子图片,均来源于无人机巡线时所拍摄的照片,采用LabelImg标准标注方法对其中的绝缘子进行人工标注,其中的4500对图片作为训练集,剩余的500对图片作为测试集。

4.2 评价指标

利用BIID-WGAN对模糊绝缘子图片进行去模糊处理后,计算生成图片与清晰绝缘子图片的峰值信噪比(PSNR)和结构相似性(SSIM),再计算模糊绝缘子图片和清晰绝缘子图片的PSNR和SSIM,对2组数据进行分析对比。

PSNR的定义如(9)所示,PSNR值越高说明2张图片的特征越接近。

$$\lambda_{\text{PSNR}} = 10 \lg \frac{I_{\text{MAX}}^2}{L_{\text{MSE}}} = 20 \lg \frac{I_{\text{MAX}}}{\sqrt{L_{\text{MSE}}}} \quad (9)$$

$$L_{\text{MSE}} = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} (I(i,j) - K(i,j))^2$$

其中, I, K 为2张图片; m, n 分别为图像的宽度和高度; I_{MAX} 为图像点颜色的最大数值; L_{MSE} 为图像 I, K 的均方差。

SSIM的定义如式(10)所示。

$$\tau_{\text{SSIM}(x,y)} = \frac{(2\mu_I \mu_K + c_1)(2\sigma_{IK} + c_2)}{(\mu_I^2 + \mu_K^2 + c_1)(\sigma_I^2 + \sigma_K^2 + c_2)} \quad (10)$$

$$c_1 = (k_1 L)^2, \quad c_2 = (k_2 L)^2$$

其中, μ_I, μ_K 分别为图像 I, K 的平均值; σ_I^2, σ_K^2 分别为图像 I, K 的方差; μ_{IK} 为图像 I 和 K 的协方差; c_1, c_2 为用于维持稳定的常数; $k_1 = 0.01; k_2 = 0.03; L$ 为像素值的动态范围。SSIM的取值范围为0~1,SSIM越大说明2张图片的相似度越高,当2张图片完全相同时,SSIM为1。

采用Faster-RCNN目标检测算法对绝缘子图片进行检测,该算法相对于SSD、YOLO等目标检测算法能够更好地识别复杂背景下的绝缘子,且检测精度更高,是目前解决目标识别最常用方法之一。

4.3 实验结果及分析

4.3.1 模型改进前后指标对比

为了验证引用的残差网络和Wasserstein距离的有效性,本文对比以下4种网络结构的PSNR、SSIM和平均生成时间:

- (1)没有做任何改进的GAN(GAN);
- (2)引入残差网络的GAN(Resnet+GAN);
- (3)WGAN;
- (4)引入残差网络和Wasserstein距离的GAN

(Resnet+WGAN)。

4种网络结构的对比结果如表1所示。由表可见,Resnet+WGAN的指标最优,去模糊效果最好。引入残差网络和 Wasserstein 距离可以加强 GAN 对权重改变的敏感性,并且能够更好地调整梯度,使得生成的绝缘子图片更加清晰。

表1 4种网络结构对比

网络	PSNR	SSIM	平均生成时间 / s
GAN	22.31	0.603	0.894
Resnet+GAN	22.84	0.657	0.108
WGAN	23.24	0.674	0.904
Resnet+WGAN	23.95	0.712	1.223

4.3.2 绝缘子图片去模糊

将模糊绝缘子图片作为生成器的输入,反复训练生成器和判别器,直到生成器生成以假乱真的清晰绝缘子图片,BIID-WGAN的损失函数变化见图4。图中, d_{loss} 为判别器损失; $d_{on_g_loss}$ 为整个模型损失。

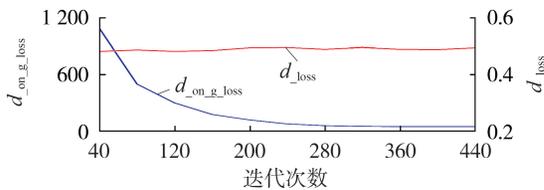


图4 BIID-WGAN的损失函数

Fig.4 Loss function of BIID-WGAN

由图4可见, d_{loss} 在整个训练过程的前期呈现缓慢上升的状态,后期都保持在0.5左右,但这并不代表判别器的性能在后面的训练过程中没有提升。在BIID-WGAN的末尾采用的损失函数是感知损失和 Wasserstein 损失函数的结合,比例为100:1。判别器的损失函数会放大100倍反馈到生成器中,生成器根据反馈结果提升生成性能,生成质量更高的清晰绝缘子图片,判别器在面对更高质量的清晰绝缘子图片时,损失函数仍保持在0.5左右,这说明判别器网络已经随着生成器网络性能的提升而提升; $d_{on_g_loss}$ 在整个训练过程不断下降,经过300次迭代后最终稳定在50左右,代表BIID-WGAN训练结束。将剩下的200张模糊绝缘子图片输入生成器中,即可生成清晰绝缘子图片。

为了证明本文算法生成的绝缘子图片清晰度更高,且生成速度更快,将其与文献[23]的基于卷积神经网络(CNN)的图像去模糊算法、文献[24]的基于深度多尺度卷积神经网络(DM-CNN)的图片去模糊算法、文献[25]的基于特定类别先验(CSP)的图像去模糊算法、文献[26]的基于暗通道优先(DCP)的图像去模糊算法和文献[27]的基于非自然L0稀疏表示(ULSR)的图像去模糊算法进行对比,图片生成结果见附录中的图A7,图A7(a)为模糊绝缘子图片,

图A7(b)~(g)分别为利用CNN、DM-CNN、ULSR、CSP、DCP和本文算法对图A7(a)进行去模糊操作之后的结果。由图可见,CNN算法的去模糊效果虽然比较好,但是色彩还原度较低;DM-CNN算法的色彩还原效果较好,但是棱角过于锐化,边缘信息缺失比较多,不利于后续的目标检测;ULSR、CSP算法的去模糊效果较一般,相对于本文算法的生成图(图A7(g)),细节还原度不够;DCP算法得到的图片虽然比较清晰,但是图片中部分信息已经缺失。综上所述,本文算法的生成效果是最好的,在不损失图片信息的情况下尽可能地提升了图片质量,边缘也比较清晰,更有利于后续的目标检测。

6种算法的PSNR、SSIM和平均生成时间对比如表2所示。根据表2的结果可知,本文算法生成的清晰图片的PSNR相对于模糊绝缘子图片的PSNR提高了2左右,SSIM提高了约0.15,均高于其他5种算法的提高量,生成速度也比其他5种算法更快。

表2 6种算法的PSNR、SSIM和生成时间对比

生成算法	PSNR	SSIM	平均生成时间 / s
CNN	22.37	0.624	6.87
DM-CNN	22.45	0.653	12.85
ULSR	22.98	0.698	900.00
CSP	23.61	0.706	5.26
DCP	23.89	0.698	3.27
WGAN	23.95	0.712	1.22
模糊绝缘子图片	21.96	0.562	—

4.3.3 基于Faster-RCNN的绝缘子目标检测

为了验证本文方法能够提高绝缘子的目标检测率,本文利用Faster-RCNN对上述生成结果进行了绝缘子目标检测。

在Faster-RCNN训练过程中,在绝缘子图片上随机采样256个目标建议框进行训练。其中,设置动量参数为0.8、权重衰减系数为0.0005、初始学习率为0.01,在训练2000次后,降低学习率,继续训练直至总体损失基本不变^[28]。训练过程中的总体损失变化如图5所示。

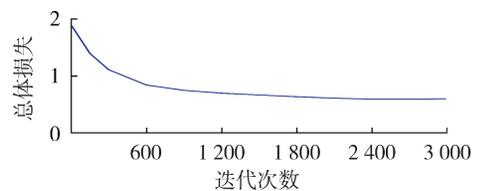


图5 Faster-RCNN的损失函数

Fig.5 Loss function of Faster-RCNN

模型训练完成后,将上述生成的绝缘子图片输入Faster-RCNN中,得到的检测结果见附录中的图A8。由图可见,在模糊绝缘子图片中利用Faster-

RCNN对绝缘子进行目标检测时,因为绝缘子图片模糊导致绝缘子检测率比较低,且部分图片已经出现了绝缘子漏检的情况。在利用本文算法进行去模糊处理后再进行绝缘子检测,发现绝缘子的检测率得到了提升,绝缘子漏检的情况也得到了改善。为了防止检测过程中部分图片检测误差过大,所以将测试集的500对图片随机分为3组分别计算精确度均值AP(Average Precision)和检测时间,AP值越大,则说明识别准确率越高,对比结果见表3。

表3 模糊图与清晰图的AP值和检测时间对比

Table 3 Comparison of AP value and detection time between fuzzy and clear images

图片	AP / %			检测时间 / s		
	A组	B组	C组	A组	B组	C组
模糊绝缘子图片	82.85	81.16	82.27	88.62	82.89	88.25
清晰绝缘子图片	25.10	25.50	25.10	25.30	25.50	25.40

由表3可见,3组数据在检测时间上基本保持一致,AP值分别提高了5.77%、6.73%、5.98%,这说明利用Faster-RCNN目标检测算法对本文算法生成的清晰绝缘子图片进行目标检测时,在不消耗更多时间的情况下,提高了绝缘子目标检测率。

5 结论

针对不可抗力因素造成无人机航拍绝缘子图片模糊、绝缘子目标检测率较低的问题,本文提出了基于WGAN图片去模糊的绝缘子目标检测方法,通过在WGAN训练过程中引入残差网络模块和Wassersstein距离,生成更高质量的绝缘子图片的同时提高了模糊绝缘子图片的目标检测率,为无人机航拍绝缘子的状态检测及故障诊断奠定了坚实的基础。

在实际应用过程中,采集的绝缘子图片可能会因为天色昏暗、图像分辨率过高或者绝缘子类型比较少见的原因而与训练集样本差异性过大,BIID-WGAN模型对这类绝缘子图片进行去模糊操作时可能会影响其性能,下一步将扩充绝缘子样本集和继续改进BIID-WGAN模型,增强模型的泛化能力,提高生成图片的清晰度,以更好满足实际工程需要。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

[1] 黄建才,朱永利. 基于FFT和ITD的绝缘子泄漏电流去噪[J]. 电力自动化设备,2013,33(10):101-106.
HUANG Jiancai,ZHU Yongli. Insulator leakage current denoising based on FFT and ITD[J]. Electric Power Automation Equipment,2013,33(10):101-106.

[2] 彭向阳,钟清,饶章权,等. 基于无人机紫外检测的输电线路电晕放电缺陷智能诊断技术[J]. 高电压技术,2014,40(8):2292-2298.
PENG Xiangyang,ZHONG Qing,RAO Zhangquan,et al. Intelligent diagnostic techniques of transmission lines corona discharge defect based on ultraviolet detection from unmanned

aerial vehicle[J]. High Voltage Engineering,2014,40(8):2292-2298.

- [3] 张焯,冯玲,穆靖宇,等. 输电线路绝缘子覆冰厚度图像识别算法[J]. 电力系统自动化,2016,40(21):195-202.
ZHANG Ye,FENG Ling,MU Jingyu,et al. Image identification algorithm of icing thickness for insulator in power transmission lines[J]. Automation of Electric Power Systems,2016,40(21):195-202.
- [4] 全卫国,苑津莎,李宝树. 图像处理技术在直升机巡检输电线路中的应用综述[J]. 电网技术,2010,34(12):204-208.
TONG Weiguo,YUAN Jinsha,LI Baoshu. Application of image processing in patrol inspection of overhead transmission line by helicopter[J]. Power System Technology,2010,34(12):204-208.
- [5] 黄凯奇,陈晓棠,康运锋,等. 智能视频监控技术综述[J]. 计算机学报,2015,38(6):1093-1118.
HUANG Kaiqi,CHEN Xiaotang,KANG Yunfeng,et al. Intelligent visual surveillance:a review[J]. Chinese Journal of Computers,2015,38(6):1093-1118.
- [6] 翟永杰,王迪,伍洋,等. 基于骨架提取的航拍绝缘子图像分步识别方法[J]. 华北电力大学学报(自然科学版),2015,42(3):105-110.
ZHAI Yongjie,WANG Di,WU Yang,et al. Two-stage recognition method of aerial insulator images based on skeleton extraction[J]. Journal of North China Electric Power University (Natural Science Edition),2015,42(3):105-110.
- [7] 左国玉,马蕾,徐长福,等. 基于跨连接卷积神经网络的绝缘子检测方法[J]. 电力系统自动化,2019,43(4):101-108.
ZUO Guoyu,MA Lei,XU Changfu,et al. Insulator detection method based on cross-connected convolutional neural network[J]. Automation of Electric Power Systems,2019,43(4):101-108.
- [8] 陈文贺,李彩林,袁斌,等. 有效的绝缘子自爆缺陷定位方法[J]. 计算机工程与设计,2019,40(8):2346-2352.
CHEN Wenhe,LI Cailin,YUAN Bin,et al. Effective method to locate self-explosion defects of insulators[J]. Computer Engineering and Design,2019,40(8):2346-2352.
- [9] 赖秋频,杨军,谭本东,等. 基于YOLOv2网络的绝缘子自动识别与缺陷诊断模型[J]. 中国电力,2019,52(7):31-39.
LAI Qiupin,YANG Jun,TAN Bendong,et al. An automatic recognition and defect diagnosis model of transmission line insulator based on YOLOv2 network[J]. Electric Power,2019,52(7):31-39.
- [10] 王坤峰,苟超,段艳杰,等. 生成式对抗网络GAN的研究进展与展望[J]. 自动化学报,2017,43(3):321-332.
WANG Kunfeng,GOU Chao,DUAN Yanjie,et al. Generative adversarial networks:the state of the art and beyond[J]. Acta Automatica Sinica,2017,43(3):321-332.
- [11] 唐贤伦,杜一铭,刘雨微,等. 基于条件深度卷积生成对抗网络的图像识别方法[J]. 自动化学报,2018,44(5):855-864.
TANG Xianlun,DU Yiming,LIU Yuwei,et al. Image recognition with conditional deep convolutional generative adversarial networks[J]. Acta Automatica Sinica,2018,44(5):855-864.
- [12] LEDIG C,THEIS L,HUSZAR F,et al. Photo-realistic single image super-resolution using a generative adversarial network[C]//2017 IEEE CVF Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA: IEEE, 2017: 105-114.
- [13] ARJOVSKY M,CHINTALA S,BOTTOU L. Wasserstein GAN[J]. Arxiv,2017,1:1-30.
- [14] HE Kaiming,ZHANG X,REN S,et al. Deep residual learning

- for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Seattle,WA,USA: IEEE,2016:770-778.
- [15] 尹宏鹏,陈波,柴毅,等. 基于视觉的目标检测与跟踪综述[J]. 自动化学报,2016,42(10):1466-1489.
YIN Hongpeng, CHEN Bo, CHAI Yi, et al. Vision-based object detection and tracking: a review[J]. Acta Automatica Sinica, 2016, 42(10): 1466-1489.
- [16] 魏铤,胡顺强,陈诚,等. 无人机模糊图像自动检测方法[J]. 地球信息科学学报,2017,19(7):962-971.
WEI Lai, HU Shunqiang, CHEN Cheng, et al. The research on automatic blur detection in UAV image[J]. Journal of Geo-Information Science, 2017, 19(7): 962-971.
- [17] LUCAS A, LOPEZ-TAPIAD S, MOLINAE R, et al. Generative adversarial networks and perceptual losses for video super-resolution[J]. IEEE Transactions on Image Processing, 2019, 18(7):3312-3327.
- [18] 蒋芸,谭宁. 基于条件深度卷积生成对抗网络的视网膜血管分割[J/OL]. 自动化学报. (2018-08-27)[2019-09-01]. <https://doi.org/10.16383/j.aas.c180285>.
- [19] DENG Jia, DONG Wei, SOCHER R. ImageNet: a large-scale hierarchical image database [C]//2009 IEEE Conference on Computer Vision and Pattern Recognition. Miami,FL,USA:IEEE, 2009:1-8.
- [20] 蔡晓龙. 基于DCGAN算法的图像生成技术研究[D]. 青岛:青岛理工大学,2018.
CAI Xiaolong. Research on image generation technology based on DCGAN algorithm[D]. Qingdao: Qingdao Technological University, 2018.
- [21] 张巍,张筱,万永菁. 基于条件生成对抗网络的书法字笔画分割[J/OL]. 自动化学报. (2019-06-11)[2019-09-01]. <https://doi.org/10.16383/j.aas.c190141>.
- [22] 孙亮,韩毓璇,康文婧,等. 基于生成对抗网络的多视图学习与重构算法[J]. 自动化学报,2018,44(5):819-828.
SUN Liang, HAN Yuxuan, KANG Wenjing, et al. Multi-view learning and reconstruction algorithms via generative adversarial networks[J]. Acta Automatica Sinica, 2018, 44(5): 819-828.
- [23] SUN Jian, CAO Wenfei, XU Zongben, et al. Learning a convolutional neural network for non-uniform motion blur removal [C]//The IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Boston,MA,USA:IEEE, 2015:769-777.
- [24] NAH S, KIM T H, LEE K M. Deep multi-scale convolutional neural network for dynamic scene deblurring[C]//30th IEEE / CVF Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu,HI,USA:IEEE, 2017:257-265.
- [25] SAEED A, PHUOC H C, FATIH P. Image deblurring with a class-specific prior[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 41(9):2112-2230.
- [26] PAN J S, SUN D Q, PFISTER H, et al. Deblurring images via dark channel prior[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(10):2315-2328.
- [27] XU Li, ZHENG Shicheng, JIA Jiaya. Unnatural L0 sparse representation for natural image deblurring [C]//2013 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Portland,OR,USA:IEEE, 2013:1107-1114.
- [28] 林刚,王波,彭辉,等. 基于改进Faster-RCNN的输电线巡检图像多目标检测及定位[J]. 电力自动化设备, 2019, 39(5): 213-218.
LIN Gang, WANG Bo, PENG Hui, et al. Multi-target detection and location of transmission line inspection image based on improved Faster-RCNN[J]. Electric Power Automation Equipment, 2019, 39(5): 213-218.

作者简介:



王德文

王德文(1973—),男,河北保定人,副教授,博士,研究方向为电力系统自动化与智能信息处理(**E-mail**:wdewen@gmail.com);

李业东(1997—),男,安徽蚌埠人,硕士研究生,主要研究方向为人工智能与图像处理(**E-mail**:1341152770@qq.com)。

(编辑 任思思)

Insulator object detection based on image deblurring by WGAN

WANG Dewen^{1,2}, LI Yedong^{1,2}

(1. School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China;

2. Engineering Research Center of Intelligent Computing for Complex Energy Systems, Ministry of Education, Baoding 071003, China)

Abstract: Due to the force majeure factor, the aerial images of insulator took by drone is fuzzy and the object detection rate of insulator is low. Aiming at this problem, an insulator object detection method based on image deblurring by WGAN (Wasserstein-Generative Adversarial Network) is proposed. The residual network is introduced in the WGAN training process, which makes the generated insulator picture clearer. Then the Wasserstein distance is introduced into the loss function to ensure the stability of the training process. Finally, by optimizing the training process of the model, the reduction degree of generated insulator pictures' details is improved. The results of defuzzification experiments show that the proposed method is superior to traditional deblurring algorithms such as CNN (Convolutional Neural Network) and DM-CNN (Deep Multi-scale Convolutional Neural Network) in terms of structural similarity and peak signal-to-noise ratio. In addition, the insulator image and the fuzzy insulator image generated by the proposed method are divided into three groups, the target detection experiment is carried out by Faster-RCNN (Faster Region-Convolutional Neural Network) target detection algorithm, with the average accuracy increased by 5.77%, 6.73% and 5.98% respectively, which improves the insulator target detection rate of the insulator effectively.

Key words: electric insulators; object detection; Wasserstein-generative adversarial network; deblurring; residual network

附录

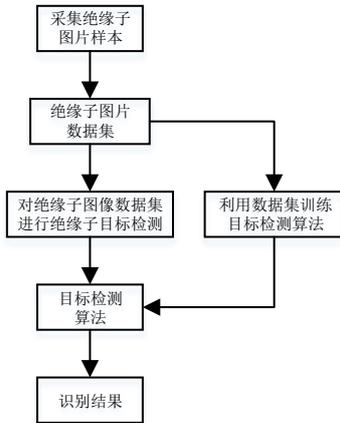


图 A1 绝缘子图片目标检测流程

Fig.A1 Flowchart of target detection for insulator

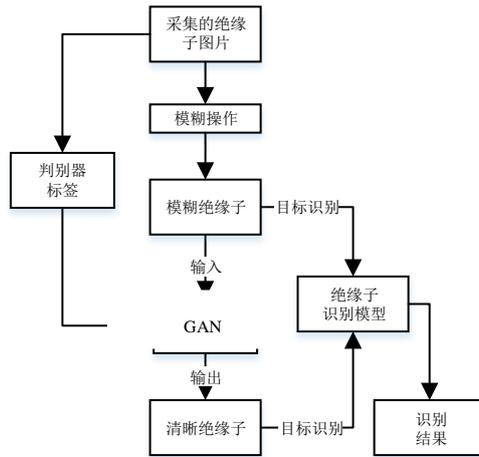


图 A2 模糊绝缘子图片识别模型

Fig.A2 Object detection model of blur insulator picture

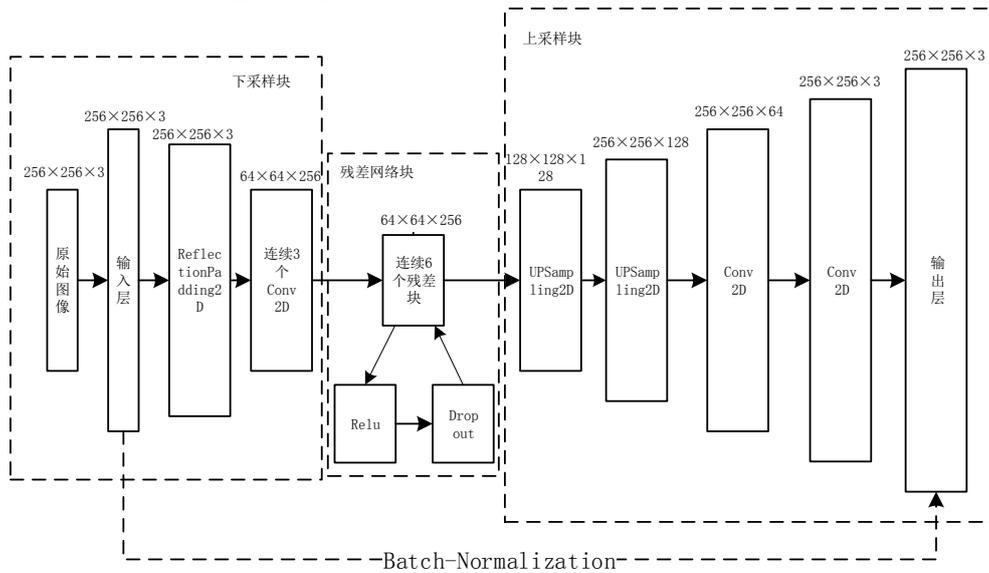


图 A3 生成器结构

Fig.A3 Structure of generation

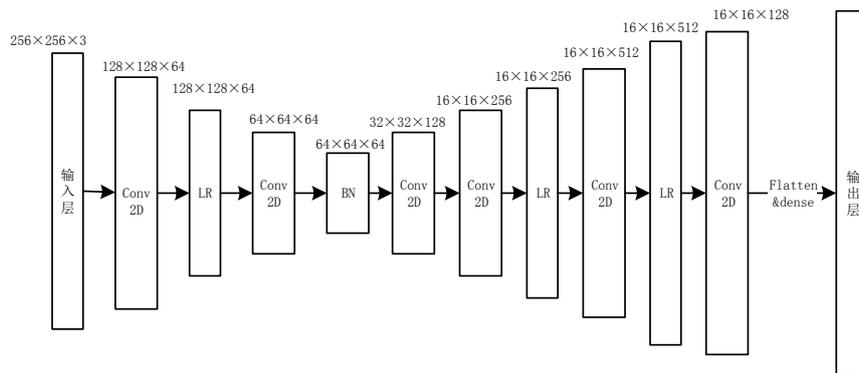


图 A4 判别器网络结构

Fig.A4 Structure of discriminator

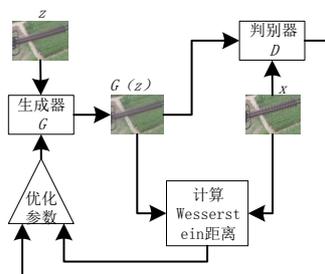


图 A5 生成器训练过程

Fig.A5 Training process of generator

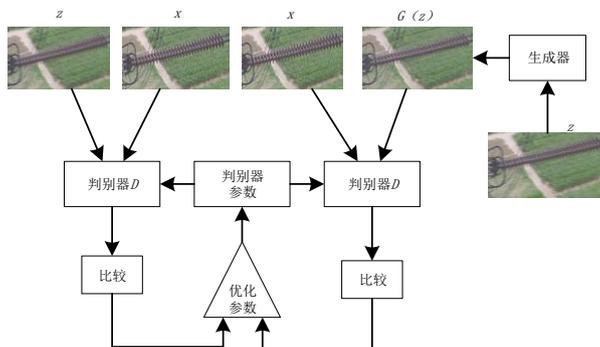


图 A6 判别器训练过程

Fig.A6 Training process of discriminator





(a) 模糊绝缘子图片 (b) CNN 算法 (c) DM-CNN 算法 (d) ULSR 算法



(e) CSP 算法 (f) DCP 算法 (g) WGAN 算法

图 A7 模糊绝缘子图片和生成的清晰绝缘子图片对比

Fig.A7 Comparison between of blur insulator picture and generated clear insulator picture





(a) 模糊的绝缘子图片检测结果 (b) BIID-WGAN 算法生成的清晰绝缘子图片检测结果

图 A8 目标检测对比

Fig A8 Comparison of object detection