



基于循环互相关系数的CGAN温度值图像扩增

王凯旋, 任福继, 倪红军, 吕帅帅, 汪兴兴

引用本文:

王凯旋, 任福继, 倪红军, 等. 基于循环互相关系数的CGAN温度值图像扩增[J]. *智能系统学报*, 2022, 17(1): 32–40.

WANG Kaixuan, REN Fuji, NI Hongjun, et al. Image amplification for temperature value image based on cyclic cross-correlation coefficient CGAN[J]. *CAAI Transactions on Intelligent Systems*, 2022, 17(1): 32–40.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202106036>

您可能感兴趣的其他文章

基于小样本学习的LCD产品缺陷自动检测方法

An automatic small sample learning-based detection method for LCD product defects
智能系统学报. 2020, 15(3): 560–567 <https://dx.doi.org/10.11992/tis.201904020>

多层卷积特征的真实场景下行人检测研究

Research on pedestrian detection based on multi-layer convolution feature in real scene
智能系统学报. 2019, 14(2): 306–315 <https://dx.doi.org/10.11992/tis.201710019>

一种改进的深度学习的路标识别算法

An improved deep learning algorithm for road traffic identification
智能系统学报. 2020, 15(6): 1121–1130 <https://dx.doi.org/10.11992/tis.201811009>

基于生成式对抗网络的道路交通模糊图像增强

Enhancement of blurred road-traffic images based on generative adversarial network
智能系统学报. 2020, 15(3): 491–498 <https://dx.doi.org/10.11992/tis.201903041>

融合整体与局部信息的武夷岩茶叶片分类方法

Classification of Wuyi rock tealeaves by integrating global and local information
智能系统学报. 2020, 15(5): 919–924 <https://dx.doi.org/10.11992/tis.202003018>

基于医学征象和卷积神经网络的肺结节CT图像哈希检索

Hashing retrieval for CT images of pulmonary nodules based on medical signs and convolutional neural networks
智能系统学报. 2017, 12(6): 857–864 <https://dx.doi.org/10.11992/tis.201706035>

 微信公众平台



关注微信公众号, 获取更多资讯信息

DOI: 10.11992/tis.202106036

网络出版地址: <https://kns.cnki.net/kcms/detail/23.1538.TP.20211214.1645.007.html>

基于循环互相关系数的 CGAN 温度值图像扩增

王凯旋^{1,2}, 任福继², 倪红军¹, 吕帅帅¹, 汪兴兴¹

(1. 南通大学机械工程学院, 江苏南通 226019; 2. 德岛大学智能信息工学部, 日本德岛 7708501)

摘要: 针对变电设备红外图像温度值样本少、不均衡等问题, 本文提出了一种基于循环互相关系数的条件生成对抗网络 (conditional generative adversarial network, CGAN) 温度值图像扩增方法。根据图像相似度提出了循环互相关系数, 改进了 CGAN 模型的损失函数; 使用改进后的 CGAN 模型在原始温度值图像数据集的基础上进行图像扩增, 得到了包含 11 种标签的新数据集; 采用卷积神经网络对传统图像扩增方法、原始 CGAN 模型和改进的 CGAN 模型扩增的图像进行对比和测试。结果表明, 改进的 CGAN 模型收敛速度更快, 训练过程稳定, 扩增的图像轮廓清晰、细节丰富, 客观评价指标最高, 温度值识别准确率达到 99.4%, 实现了图像扩增的目的。

关键词: 红外图像; 图像扩增; 循环互相关系数; 条件生成对抗网络; 卷积神经网络; 变电设备; 损失函数; 图像处理; 温度识别

中图分类号: TP181 文献标志码: A 文章编号: 1673-4785(2022)01-0032-09

中文引用格式: 王凯旋, 任福继, 倪红军, 等. 基于循环互相关系数的 CGAN 温度值图像扩增 [J]. 智能系统学报, 2022, 17(1): 32-40.

英文引用格式: WANG Kaixuan, REN Fuji, NI Hongjun, et al. Image amplification for temperature value image based on cyclic cross-correlation coefficient CGAN[J]. CAAI transactions on intelligent systems, 2022, 17(1): 32-40.

Image amplification for temperature value image based on cyclic cross-correlation coefficient CGAN

WANG Kaixuan^{1,2}, REN Fuji², NI Hongjun¹, LYU Shuaishuai¹, WANG Xingxing¹

(1. School of Mechanical Engineering, Nantong University, Nantong 226019, China; 2. Department of Intelligent Information Engineering, Tokushima University, Tokushima 7708501, Japan)

Abstract: To solve the problems of small sample size and imbalance of infrared image for substation equipment, a temperature image amplification method based on cyclic cross-correlation coefficient conditional generative adversarial network (CGAN) is proposed. The cyclic cross-correlation coefficient is proposed according to the image similarity, which improves the loss function of CGAN. Then the improved CGAN is used to amplify the original temperature image data set, establishing a new data set containing 11 labels. Then, the traditional image amplification method, the original CGAN and the improved CGAN are compared using the convolution neural network (CNN). The experiment demonstrate that the proposed CGAN model has faster convergence speed and stable training process, and the generated images have clear contour and rich details. The objective evaluation index of the proposed method is the largest, and the recognition accuracy of temperature value reaches 99.4%, which realizes the purpose of the image amplification.

Keywords: infrared image; image amplification; cyclic cross-correlation coefficient; conditional generative adversarial network; convolution neural network; substation equipment; loss function; image processing; temperature recognition

变电设备是电能输送的重要组成部分, 由于长期暴露在复杂的环境中, 容易产生裂缝、老化、

腐蚀等缺陷, 引起变电设备温度异常, 影响电力系统的稳定性^[1-2]。基于红外图像的缺陷检测技术能够根据变电设备的热效应特点判断是否存在缺陷, 具有操作简单、检测时间快、灵敏度高等优点^[3]。因此, 通过识别红外图像中的温度值, 能够

收稿日期: 2021-06-29. 网络出版日期: 2021-12-15.

基金项目: 江苏高校优势学科建设工程项目 (PAPD); 德岛大学研究集群项目 (2003002).

通信作者: 倪红军. E-mail: ni.hj@ntu.edu.cn.

快速筛选出缺陷, 并方便统计和记录。在实际巡检过程中, 由于变电设备检测的周期较长、温度变化不确定性高, 采集的红外图像温度值样本较少, 存在数据集不平衡问题, 无法满足模型的训练要求^[4-5]。

针对此问题, 图像扩增技术通过增加训练集数量, 可以有效缓解训练时产生的过拟合和梯度下降现象^[6-7]。近年来, 研究学者们对基于机器学习技术的图像扩增方法进行了大量研究^[8-10]。Goodfellow 等^[11]受博弈论思想的影响率先提出了生成对抗网络 (generative adversarial network, GAN), 通过生成器和判别器的对抗训练, 不断学习样本的数据分布。Han 等^[12]提出了一种基于改进 GAN 的遥感图像生成方法, 采用沃瑟斯坦距离测量生成分布与真实分布间的差异, 解决了训练过程中梯度消失等问题。Song 等^[13]将 GAN 输入噪声限制为二进制, 并且采用多任务和无监督方式将图像转换成二进制编码同时进行图像压缩和检索。Guo 等^[14]在判别器中加入对比度增强操作, 并将原始 GAN 的多层感知层替换为深度卷积神经网络, 增强了图像细节和特征提取能力。这些方法虽然能够有效地增加样本数量, 但是针对真实场景中的复杂背景图像缺乏特征分析, 无法保证生成图像的质量。

为扩增变电设备温度值图像并提高生成图像质量, 本文提出了基于循环互相关系数的 CGAN 温度值图像扩增方法。提出了一种循环互相关系数改进原始 CGAN 模型的损失函数, 实现了数据集的扩增, 在提高生成图像质量的同时解决了原始 CGAN 模型训练过程不稳定和过拟合的问题; 在此基础上, 通过对比实验验证了模型的有效性, 实现了红外图像中温度值的高效准确识别, 为后期的性能分析和故障诊断提供大量的红外温度值数据。

1 条件生成对抗网络

条件生成对抗网络 (conditional generative adversarial network, CGAN) 通过输入随机噪声和标签信息来引导数据的生成过程^[15-16], 由生成器 (generator, G) 和判别器 (discriminator, D) 组成。生成器 G 生成具有标签特征的样本, 判别器 D 用于区分生成样本与真实样本^[17]。

CGAN 模型的损失函数包括生成器和判别器两部分, 如式 (1) 所示, 目标函数如式 (2) 所示, 在样本数据小的情况下, CGAN 采用随机噪声作为基础生成的图像会存在若干畸形图像, 这会直接

影响损伤函数的计算结果, 使得 CGAN 无法收敛, 模型的稳定性较差^[18]。

$$\begin{cases} L_G = -\frac{1}{n} \sum_{i=1}^n \log D(\mathbf{G}_{Z_i,y}) \\ L_D = -\frac{1}{m} \sum_{j=1}^m \log D(\mathbf{R}_{j,y}) - \frac{1}{n} \sum_{i=1}^n \log [1 - D(\mathbf{G}_{Z_i,y})] \end{cases} \quad (1)$$

$$\min_G \max_D V(D, G) = E_{R \sim P_R} [\log D(\mathbf{R}_y)] + E_{Z \sim P_G} \{\log [1 - D(\mathbf{G}_y)]\} \quad (2)$$

式中: m, n 分别表示真实图像和生成图像数量; Z_i 表示第 i 张噪声; $\mathbf{G}_{Z_i,y}$ 表示标签为 y 的第 i 张生成图像; $\mathbf{R}_{j,y}$ 表示标签为 y 的第 j 张真实图像, 表示标签为 y 的生成图像; \mathbf{R}_y 表示标签为 y 的真实图像; P_R, P_G 分别表示真实图像集和生成图像集; D 表示判别网络的判别结果。

2 基于改进 CGAN 的图像扩增方法

2.1 基于循环互相关系数的改进损失函数

2.1.1 循环互相关系数

相关系数反映两张图像间的相关程度, 相关系数越大, 表明两张图像越相似^[19]。相关系数的计算如式 (3) 所示。由于两张图像间的相关系数存在较大的偶然性, 本文提出一种循环互相关系数 δ , 用于表征不同标签图像间的相关性, 提高生成图像质量和多样性。其中, δ 取值范围为 $[0, 1]$, 数值越大表明图像之间越相似, 其计算过程如图 1 所示。

$$\begin{aligned} \delta_{V_1, V_2} &= \frac{\sum_{i=1}^n \sum_{j=1}^m V_1(i, j) \cdot V_2(i, j)}{\sqrt{\delta_{V_1, V_1}} \times \sqrt{\delta_{V_2, V_2}}} \\ \delta_{V_1, V_1} &= \sum_{i=1}^n \sum_{j=1}^m V_1(i, j) \cdot V_1(i, j) \\ \delta_{V_2, V_2} &= \sum_{i=1}^n \sum_{j=1}^m V_2(i, j) \cdot V_2(i, j) \end{aligned} \quad (3)$$

式中: i, j 表示像素点的位置; m, n 是图像长和宽。




图 1 循环互相关系数计算流程

Fig. 1 Flowchart of cyclic cross-correlation coefficient

设标签 A 图像为 VA_1, VA_2, \dots, VA_n , 标签 B 图像为 VB_1, VB_2, \dots, VB_m , 当计算标签 A 和标

签 B 的循环互相关系数 δ_{A_1, B_1} 时, 其计算过程为: 从标签 A 中取出图像 VA_1 , 分别计算 VA_1 与标签 B 中图像 VB_1, VB_2, \dots, VB_m 的相关系数, 即 $\delta_{A_1, B_1}, \delta_{A_1, B_2}, \dots, \delta_{A_1, B_m}$, 将其平均值作为图像 VA_1 与标签 B 的相关系数 $\delta_{A_1, B}$; 以此类推, 分别计算 VA_2, VA_3, \dots, VA_n 与标签 B 的相关系数 $\delta_{A_2, B}, \delta_{A_3, B}, \dots, \delta_{A_n, B}$; 最后计算所有标签 A 图像与标签 B 中相关系数的平均值, 得到最终的循环互相关系数, 如式 (4):

$$\begin{aligned} \delta_{A_1, B} &= \frac{\sum_{j=1}^m \delta_{A_1, B_j}}{m} \\ \delta_{A, B} &= \frac{\sum_{i=1}^n \delta_{A_i, B}}{n} \end{aligned} \quad (4)$$

式中: n, m 分别是标签 A 和标签 B 图像的数量。

2.1.2 改进的损失函数

为了提高生成图像质量, 基于循环互相关系数改进生成器和判别器的损失函数, 如式 (5), 目标函数如式 (6):

$$\begin{cases} L_{G\delta} = -\frac{1}{n} \sum_{i=1}^n \log [\delta_{G(z_i|y), y} \times D(G_{z_i, y})] \\ L_{D\delta} = -\frac{1}{m} \sum_{j=1}^m \log (\delta_{R_{j, y}} \times D(R_{j, y})) - \\ \frac{1}{n} \sum_{i=1}^n \log [1 - \delta_{G_{z_i, y}} \times D(G_{z_i, y})] \end{cases} \quad (5)$$

$$\min_G \max_D V(D, G) = E_{x \sim P_R} [\log (\delta_{R_{j, y}} \times D(R_{j, y}))] + E_{z \sim P_G} \{\log [1 - \delta_{G_{z_i, y}} \times D(G_{z_i, y})]\} \quad (6)$$

式中: $\delta_{R_{j, y}}$ 表示标签 y 的第 j 张生成图像与各标签图像的最大循环互相关系数; $\delta_{V_i, y}$ 表示标签 y 的第 j 张真实图像与各标签图像的最大循环互相关系数。

当图像 V_1 输入到判别器 D 后, 计算此图像与各标签图像 (y_1, y_2, \dots, y_{11}) 的循环互相关系数, 取其最大值。当此图像实际为真实标签的图像时, 则 $\delta_{V_i, y}$ 趋于 1; 当此图像实际为假标签的图像时, 则 $\delta_{V_i, y}$ 趋于 0, 从而纠正了判别器将假判断为真和将真判断为假的情况。此外, 为了减少判别器 D 的识别效果对生成器 G 的影响, 更好地平衡生成器 G 和判别器 D 的训练过程, 随机将一定比例的真实图像判别结果进行随机翻转操作, 从而降低判别器的准确率并提升生成器的训练效果, 解决过拟合现象。

2.2 网络设计

本文的生成器网络和判别器网络结构如图 2 所示, 训练过程如下。

1) 将随机噪声和标签输入到生成器 G 中得到生成图像, 固定判别器 D , 分别计算生成图像与 11 种标签图像的循环互相关系数, 选取上述循环互相关系数的最大值改进损失函数, 优化生成器 G 参数;

2) 接着固定生成器 G , 同时将生成图像、真实图像和标签输入到判别器 D 中, 判断图像的真假, 并根据图像与 11 种标签图像的循环互相关系数最大值改进损失函数;

3) 将结果反馈到生成器 G 和判别器 D 中, 更新参数, 反复执行上述步骤, 使两者损失函数达到平衡, 减少了生成图像与标签不匹配的情况。

在图像扩增时, 将原始数据集中各标签内的循环互相关系数的平均值作为阈值, 当生成图像与对应标签图像之间的循环互相关系数超过此阈值时输出图像, 确保生成图像的质量, 进而搭建新的数据集。

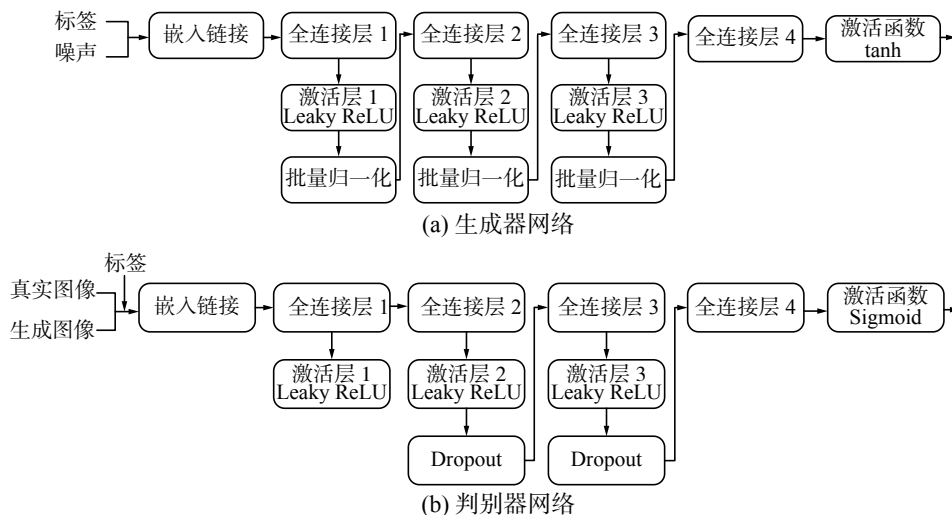


图 2 网络框架

Fig. 2 Network framework

2.3 算法流程

本文提出的基于循环互相关系数的 CGAN 温

度值图像扩增方法流程如图 3 所示, 由 4 个部分组成。

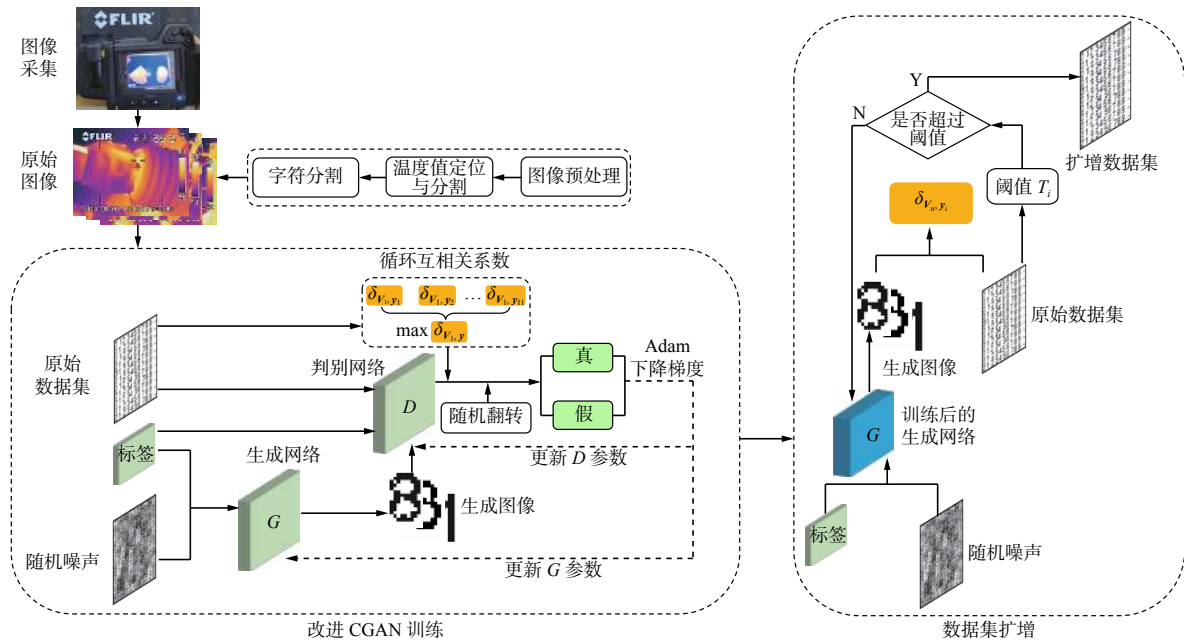


图 3 本文方法流程

Fig. 3 Flowchart of the proposed method

1) 图像采集。采用红外热成像仪采集不同类型的变电设备图像, 如绝缘子、高压套管、避雷器和转换开关等。

2) 构建原始温度值图像数据集。首先对采集的图像进行预处理, 并基于轮廓和位置信息准确定位温度值区域并进行分割, 最终得到包含数字“0~9”和符号“-”共 11 种标签的原始温度值图像数据集。

3) 训练改进的 CGAN 网络。将随机噪声和标签同时输入到生成器网络中得到生成图像, 将原始数据集和生成图像输入到判别器网络中, 结合循环相关系数判别图像真假, 经过一定比例随机翻转后进行对抗训练, 更新网络参数, 直至达到平衡。

4) 构建新温度值图像数据集。利用训练好的

改进 CGAN 网络生成图像, 结合循环相关系数提高生成图像质量, 最终建立新的温度值图像数据集。

3 实验环境与原始数据集

变电设备红外图像采用 FLIR 红外成像仪拍摄, 像素为 320×240 。硬件配置为 Intel(R)Core(TM) i5-10400F@2.90 GHz, 16.0 GB RAM, NVIDIA GTX 2060, 软件为 MATLAB 2020b。实验中设置学习率为 0.000 2、梯度衰减系数为 0.5、平方梯度衰减因子为 0.999、运行 200×27 代, 激活函数 (leaky rectified linear units, Leaky ReLU) 斜率为 0.2, 采用自适应矩估计优化器 (adaptive moment estimation, Adam) 更新网络参数, 单次批量处理 32 张图像。网络结构参数设置见表 1。

表 1 网络参数设置

Table 1 Network parameter setting

层	层类型	生成器网络			判别器网络		
		输入特征	神经元数	输出特征	输入特征	神经元数	输出特征
0	输入层	噪声 100×32 标签 32		100×32	图像 256×32 标签 32		256×32
1	全连接层 FC1	100×32	256×100	256×32	256×32	$1\ 024 \times 256$	$1\ 024 \times 32$
2	激活层 A1	256×32		256×32	$1\ 024 \times 32$		$1\ 024 \times 32$
3	全连接层 FC2	256×32	512×256	512×32	$1\ 024 \times 32$	$512 \times 1\ 024$	512×32
4	激活层 A2	512×32		512×32	512×32		512×32

续表 1

层	层类型	生成器网络			判别器网络		
		输入特征	神经元数	输出特征	输入特征	神经元数	输出特征
5	全连接层FC3	512×32	1 024×512	1 024×32	512×32	256×512	256×32
6	激活层A3	1 024×32		1 024×32	256×32		256×32
7	全连接层FC4	1 024×32	256×1 024	256×32	256×32	1×256	1×32
8	激活层A4	256×32		256×32	1×32		1×32

由于红外图像中通常包含设备水印、树木、建筑物等复杂背景^[20], 直接对红外图像识别容易检测错误, 因此需要进行图像预处理, 包括二值化处理、图像分割、温度值提取等。预处理结果如图 4 所示。随机选取 150 张变电设备红外图像进行预处理, 一共得到 876 张温度值图像, 根据温度值特点将图像分成 11 个标签, 分别是数字“0~9”和符号“-”, 并建立原始温度值图像数据集, 如表 2 所示。分析可知原数据集存在样本数量小、分配不均衡特点。

表 2 原始温度值图像数据集
Table 2 Original temperature image data set

标签	数量	标签	数量
-	20	5	49
0	60	6	38
1	149	7	46
2	179	8	36
3	184	9	43
4	72	/	/




图 4 红外图像预处理

Fig. 4 Infrared image preprocessing

4 分析与讨论

4.1 生成图像结果

采用改进的 CGAN 模型能够根据标签生成对应的图像, 扩增后的变电设备温度值数据集共有 2 200 张, 数字“0~9”和符号“-”各有 200 张。为了验证改进 CGAN 模型的有效性, 与原始 CGAN 模型损失函数曲线和生成图像进行对比, 结果如图 5 所示。可以看出, 原始 CGAN 的损失函数在初期震荡较大, 表明初期生成的样本质量较差, 随着训练次数的增加, 生成器和判别器网络相互对抗, 图像质量不断上升, 在 2 000 次训练后开始达到平衡, 但生成图像存在较大的偶然性, 部分数据不清晰、边缘模糊, 存在异常结果, 从而导致生成数据集的质量较差。改进的 CGAN 结合了循环互相关系数, 在 1 800 次迭代后达到了平衡, 训练过程较稳定, 波动较小, 且生成图像比较清晰、无异常结果, 轮廓细节更清晰, 整体图像质量较好。



(a) 原始 CGAN 损失函数

(b) 改进 CGAN 损失函数

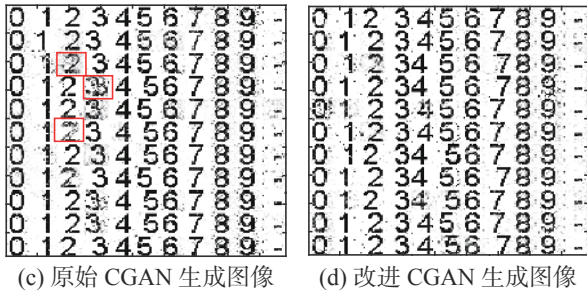


图 5 训练过程及生成图像

Fig. 5 Training process and generated images

为了验证循环互相关系数的有效性, 计算上述数据集中各标签图像间的循环互相关系数, 结果如表 3 所示。可以看出, 相同标签图像的循环相关系数超过 0.90, 而不同标签之间的循环相关系数比较小, 因此循环相关系数能够区分各标签

图像, 进而提高生成图像的质量。

4.2 客观质量评价

为了评价生成图像的质量, 结合客观质量评价方法进行分析。客观质量评价方法主要包括全参考指标、部分参考指标和无参考指标^[21-22]。本文选取峰值信噪比 (peak-signal to noise ratio, PSNR) 和结构相似度 (structure similarity, SSIM) 两种全参考指标对生成图像进行质量评价。PSNR 是基于图像像素统计的指标, 通过计算图像之间的像素误差的全局大小来评价图像质量, PSNR 值越大表明图像生成效果越好^[23]。SSIM 是基于结构信息的指标, 从亮度、对比度、结构综合评价图像相似性, 更符合人眼视觉系统特性^[24], SSIM 值越大, 生成图像质量越好。

表 3 11 种标签的循环互相关系数

Table 3 Cyclic cross-correlation coefficients of 11 labels

标签	-	0	1	2	3	4	5	6	7	8	9
-	0.951	0.295	0.245	0.541	0.128	0.083	0.606	0.662	0.323	0.655	0.674
0	0.295	0.914	0.470	0.376	0.313	0.425	0.310	0.284	0.473	0.232	0.286
1	0.245	0.470	0.962	0.284	0.263	0.325	0.259	0.231	0.385	0.199	0.237
2	0.541	0.376	0.284	0.945	0.235	0.157	0.406	0.420	0.522	0.509	0.562
3	0.128	0.313	0.263	0.235	0.936	0.111	0.092	0.028	0.254	0.001	0.052
4	0.128	0.313	0.263	0.235	0.678	0.922	0.092	0.028	0.254	0.001	0.052
5	0.606	0.310	0.259	0.406	0.092	0.109	0.947	0.735	0.369	0.607	0.560
6	0.662	0.284	0.231	0.420	0.028	0.104	0.735	0.935	0.284	0.699	0.571
7	0.323	0.473	0.385	0.522	0.254	0.334	0.369	0.284	0.947	0.277	0.335
8	0.655	0.232	0.199	0.509	0.001	0.049	0.607	0.699	0.277	0.951	0.698
9	0.674	0.286	0.237	0.562	0.052	0.068	0.560	0.571	0.335	0.698	0.904

为了验证改进的 CGAN 模型的有效性, 将本文算法与传统的图像扩增方法和原始的 CGAN 模型进行对比。传统的图像扩增方法包括图像旋

转、缩放、翻转等^[25]。分别计算 3 种方法生成图像的 PSNR 和 SSIM 值, 得到 11 种标签客观评价指标, 结果如表 4 所示。

表 4 不同图像扩增方法的客观评价指标

Table 4 Objective evaluation index of different methods

标签	传统方法		原始CGAN		改进CGAN	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
-	30.326	0.761	32.399	0.828	34.336	0.839
0	31.995	0.650	35.053	0.751	36.001	0.863
1	33.838	0.756	33.992	0.783	36.928	0.820
2	30.846	0.279	29.470	0.532	32.192	0.574
3	30.273	0.582	30.404	0.707	34.836	0.816

续表 4

标签	传统方法		原始CGAN		改进CGAN	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
4	30.773	0.507	30.343	0.566	31.599	0.677
5	30.522	0.747	29.926	0.742	33.244	0.894
6	30.317	0.806	31.324	0.717	33.728	0.808
7	31.690	0.504	32.080	0.561	33.616	0.617
8	31.232	0.727	29.051	0.842	33.557	0.853
9	30.930	0.577	31.688	0.700	31.943	0.706

从表 4 可以看出, 基于改进 CGAN 模型的图像扩增方法在 PSNR 和 SSIM 指标上数值最大, 生成图像质量更好, 证明了改进 CGAN 模型的有效性。原始 CGAN 模型在加入循环互相关系数改进损失函数后, 生成图像质量得到明显提升。例如, 相比于原始的 CGAN 模型, 数字“5”的 PSNR 值提高了 11.1%, SSIM 值提高 20.5%, 改进后的 CGAN 模型更能有效地控制生成图像的质量, 与原始图像像素分布更接近, 图像失真更小。

4.3 温度值识别对比

为了验证温度值图像扩增质量对识别准确率的影响, 将上述 3 种方法生成的 2 200 张图像按照 7:3 的比例随机分配为训练集和测试集, 采用卷积神经网络 (convolution neural network, CNN) 进行温度值识别, 并采用 10 倍交叉检验法进行验证, 结果如图 6 所示。此外, 为了验证图像扩增数量对识别准确率的影响, 分析识别准确率随样本数量变化的情况, 结果如图 7 所示。




图 6 不同方法的识别准确率

Fig. 6 Recognition accuracy of different methods




图 7 不同数量图像的识别准确率

Fig. 7 Recognition accuracy of different number of images

从图 6 可以看出, 与传统的图像扩增方法相比, 基于改进 CGAN 的图像扩增方法识别效果更好, 11 种标签的准确率均有大幅度提升。相比于原始的 CGAN 模型, 对于容易识别错误的标签“0”、“3”、“6”、“-”等, 识别的准确率分别为 87.12%、87.22%、94.41% 和 93.62%, 表明扩增后的温度值图像数据集能够提高温度值识别的准确率, 满足训练和测试的样本要求。

从图 7 可以看出, 随着生成样本数量的不断增加, 3 种方法的识别准确率均得到有效提升, 当样本数量达到 2 200 张时, 本文方法的准确率达到 99.4%, 表明数据集的大小会影响识别的准确率, 扩增温度值图像数据集具有重要意义。

5 结束语

本文针对变电设备红外图像中温度值图像数据集样本少、分布不均衡的问题, 在分析温度值图像特征的基础上, 提出了一种基于循环互相关系数的 CGAN 温度值图像扩增方法, 通过计算循环互相关系数改进损失函数, 提高生成图像的质量。经过生成器网络和判别器网络之间的对抗训练, 生成图像清晰、细节信息丰富的温度值图像。本文方法在迭代次数达到 1 800 次时更快地达到纳什平衡, 训练过程平稳。与传统方法和原始 CGAN 模型相比, 本文方法生成图像的 PSNR 和 SSIM 值均达到最大, 有效提高了生成图像的质量, 图像轮廓清晰, 与原始图像之间有更高的相似性; 采用 CNN 模型对扩增后的数据集进行温度识别, 本文方法的准确率最高, 达到 99.4%。此外, 随着生成图像样本数量的增加, 模型识别的准确率得到有效提升, 对小样本数据集扩增具有重要意义, 提高了图像之间的匹配度, 为后续的缺陷检测做充分准备。

参考文献:

- [1] 蒲天骄, 乔骥, 韩笑, 等. 人工智能技术在电力设备运维

- 检修中的研究及应用 [J]. 高电压技术, 2020, 46(2): 369–383.
- PU Tianjiao, QIAO Ji, HAN Xiao, et al. Research and application of artificial intelligence in operation and maintenance for power equipment[J]. High voltage engineering, 2020, 46(2): 369–383.
- [2] CHEN Junwen, LIU Zhigang, WANG Hongrui, et al. Automatic defect detection of fasteners on the catenary support device using deep convolutional neural network[J]. IEEE transactions on instrumentation and measurement, 2018, 67(2): 257–269.
- [3] 王有元, 李后英, 梁玄鸿, 等. 基于红外图像的变电设备热缺陷自调整残差网络诊断模型 [J]. 高电压技术, 2020, 46(9): 3000–3007.
- WANG Youyuan, LI Houying, LIANG Xuanhong, et al. Self-adjusting residual network diagnosis model for substation equipment thermal defects based on infrared image[J]. High voltage engineering, 2020, 46(9): 3000–3007.
- [4] 何佳美. 基于生成对抗网络的电力设备图像扩充模型及算法研究 [D]. 成都: 电子科技大学, 2020: 1–60.
- HE Jiamei. Research on image expansion model and algorithm of power equipment based on generative adversarial network[D]. Chengdu: University of Electronic Science and Technology of China, 2020: 1–60.
- [5] 黄锐勇, 戴美胜, 郑跃斌, 等. 电力设备红外图像缺陷检测 [J]. 中国电力, 2021, 54(2): 147–155.
- HUANG Ruiyong, DAI Meisheng, ZHENG Yuebin, et al. Defect detection of power equipment by infrared image[J]. Electric power, 2021, 54(2): 147–155.
- [6] CAO Xinhua, LI Taihao, LI Hongli, et al. A robust parameter-free thresholding method for image segmentation[J]. IEEE access, 2018, 7: 3448–3458.
- [7] 毕晓君, 潘梦迪. 基于生成对抗网络的机载遥感图像超分辨率重建 [J]. 智能系统学报, 2020, 15(1): 74–83.
- BI Xiaojun, PAN Mengdi. Super-resolution reconstruction of airborne remote sensing images based on the generative adversarial networks[J]. CAAI transactions on intelligent systems, 2020, 15(1): 74–83.
- [8] REN Fuji, LIU Wenjie, WU Guoqing. Feature reuse residual networks for insect pest recognition[J]. IEEE access, 2019, 7: 122758–122768.
- [9] HUANG Zhong, REN Fuji. Facial expression recognition based on multi-regional D-S evidences theory fusion[J]. IEEE transactions on electrical and electronic engineering, 2017, 12(2): 251–261.
- [10] YI Zili, CHEN Zhiqin, CAI Hao, et al. BSD-GAN: branched generative adversarial network for scale-disentangled representation learning and image synthesis[J]. IEEE transactions on image processing, 2020, 29: 9073–9083.
- [11] GOODFELLOW I J, POUGET ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. Communications of the ACM. 2020, 63(11): 139–144.
- [12] HAN Wei, WANG Lizhe, FENG Ruyi, et al. Sample generation based on a supervised wasserstein generative adversarial network for high-resolution remote-sensing scene classification[J]. Information sciences, 2020, 539: 177–194.
- [13] SONG Jingkuan, HE Tao, GAO Lianli, et al. Unified binary generative adversarial network for image retrieval and compression[J]. International journal of computer vision, 2020, 128(8): 2243–2264.
- [14] GUO Runyuan, LIU Han, XIE Guo, et al. Weld defect detection from imbalanced radiographic images based on contrast enhancement conditional generative adversarial network and transfer learning[J]. IEEE sensors journal, 2021, 21(9): 10844–10853.
- [15] LI Jiaosheng, LI Yuhui, LI Ju, et al. Single exposure optical image watermarking using a cGAN network[J]. IEEE photonics journal, 2021, 13(2): 6900111.
- [16] 黄远, 白琮, 李宏凯, 等. 基于条件生成对抗网络的图像描述生成方法 [J]. 计算机辅助设计与图形学学报, 2020, 32(6): 911–918.
- HUANG Yuan, BAI Cong, LI Hongkai, et al. Image captioning based on conditional generative adversarial Nets[J]. Journal of Computer-aided design & computer graphics, 2020, 32(6): 911–918.
- [17] 于文家, 丁世飞. 基于自注意力机制的条件生成对抗网络 [J]. 计算机科学, 2021, 48(1): 241–246.
- YU Wenjia, DING Shifei. Conditional generative adversarial network based on self-attention mechanism[J]. Computer science, 2021, 48(1): 241–246.
- [18] 陈佛计, 朱枫, 吴清潇, 等. 生成对抗网络及其在图像生成中的应用研究综述 [J]. 计算机学报, 2021, 44(2): 347–369.
- CHEN Foji, ZHU Feng, WU Qingxiao, et al. A survey about image generation with generative adversarial nets[J]. Chinese journal of computers, 2021, 44(2): 347–369.
- [19] 朱奇光, 张朋珍, 李昊立, 等. 基于全局和局部特征融合的图像匹配算法研究 [J]. 仪器仪表学报, 2016,

- 37(1): 170–176.
 ZHU Qiguang, ZHANG Pengzhen, LI Haoli, et al. Investigation on the image matching algorithm based on global and local feature fusion[J]. Chinese journal of scientific instrument, 2016, 37(1): 170–176.
- [20] TANG Fashuai, GAO Qi, DU Zongzhan. Algorithm of object localization applied on high-voltage power transmission lines based on line stereo matching[J]. Optical engineering, 2021, 60(2): 023101.
- [21] 曹玉东, 蔡希彪. 基于增强型对抗学习的无参考图像质量评价算法 [J]. 计算机应用, 2020, 40(11): 3166–3171.
 CAO Yudong, CAI Xibiao. No-reference image quality assessment algorithm with enhanced adversarial learning[J]. Journal of computer applications, 2020, 40(11): 3166–3171.
- [22] 方玉明, 睦相杰, 鄢杰斌, 等. 无参考图像质量评价研究进展 [J]. 中国图象图形学报, 2021, 26(2): 265–286.
 FANG Yuming, SUI Xiangjie, YAN Jiebin, et al. Progress in no-reference image quality assessment[J]. Journal of image and graphics, 2021, 26(2): 265–286.
- [23] 王耀领, 王宏琦, 许滔. CGAN 样本生成的遥感图像飞机识别 [J]. 中国图象图形学报, 2021, 26(3): 663–673.
 WANG Yaoling, WANG Hongqi, XU Tao. Aircraft recognition of remote sensing image based on sample generated by CGAN[J]. Journal of image and graphics, 2021, 26(3): 663–673.
- [24] 王伟, 刘辉, 杨俊安. 一种特征字典映射的图像盲评价方法研究 [J]. 智能系统学报, 2018, 13(6): 989–993.
 WANG Wei, LIU Hui, YANG Jun'an. Blind quality evaluation with image features codebook mapping[J]. CAAI transactions on intelligent systems, 2018, 13(6): 989–993.
- [25] 祝钧桃, 姚光乐, 张葛祥, 等. 深度学习的小样本学习综述 [J]. 计算机工程与应用, 2021, 57(7): 22–33.
 ZHU Juntao, YAO Guangle, ZHANG Gexiang, et al. Survey of few shot learning of deep neural network[J]. Computer engineering and applications, 2021, 57(7): 22–33.

作者简介:



王凯旋, 硕士研究生, 主要研究方向为电力设备缺陷检测和图像处理。



任福继, 教授, 博士, 日本工程院院士、欧盟科学院院士, 中国人工智能学会名誉副理事长、日本工学会、IE-ICE、CAAIFellow, 日本国际先进信息研究所的主席, 主要研究方向为人工智能、情感计算、自然言语理解、模式识别。获吴文俊人工智能科学技术奖创新一等奖等, 主持德岛大学研究集群项目, 申请发明专利 10 余项。发表学术论文 500 余篇。



倪红军, 教授, 博士, 现任南通大学张謇学院院长, 中国有色金属协会再生金属分会学术委员会委员, 中国再生资源产业技术创新战略联盟理事, 主要研究方向为新能源新材料及装备技术、人工智能。主持和参与科研项目 40 余项, 申请发明专利 70 余项, 获授权 37 项, 成功转让发明专利 14 项。发表学术论文 70 余篇。