光电技术及应用

DOI：10.16818/j.issn1001－5868.2022032801

基于 MDCGAN 的裂缝样本扩充及识别研究

谢永华[1]*，齐　杨[2]

（南京信息工程大学 1.计算机与软件学院；2.电子与信息工程学院，南京 210000）

摘　要： 针对裂缝图像获取困难导致的样本少、传统数据扩充方法提升样本特征空间能力不足等问题，提出了一种基于改进深度卷积生成对抗网络（MDCGAN）的裂缝样本扩充方法。首先对数据集进行预处理，利用滑窗法进行数据降维和清洗；其次优化激活函数，提高生成特征的多样性，同时引入谱归一化进行权重标准化提升网络结构的稳定性，以生成高质量的裂缝数据集；最后，利用改进的 Alexnet 网络对扩充后的混合样本集进行特征提取并分类识别。结果表明，MDCGAN 网络数据增强性能与传统扩充方法相比均有明显提高，适用于扩充裂缝图像。

关键词： 深度卷积生成对抗网络；数据增强；裂缝图像；谱归一化；激活函数

中图分类号： TP301.6　**文章编号：** 1001－5868(2022)05－0955－07

Research on Crack Sample Expansion and Recognition Based on MDCGAN

XIE Yonghua[1]，QI Yang[2]

（1. College of Computer and Software；2. College of Electronic and Information Engineering，
Nanjing University of Information Science and Technology，Nanjing 210000，CHN）

Abstract： In view of the lack of samples caused by the difficulty in obtaining crack images and the insufficient ability of traditional data expansion methods to enhance the sample feature space，a crack sample expansion method based on modified deep convolutional generative adversarial network（MDCGAN）was proposed. Firstly，the data set was preprocessed，and the sliding window method was used for data dimension reduction and cleaning. Secondly，the activation function was optimized to improve the diversity of generation features. At the same time，spectral normalization was introduced for weight standardization to improve the stability of network structure，so as to generate high-quality crack data set. Finally，the improved Alexnet network was used to extract and classify the extended mixed sample set. The results show that the data enhancement performance of MDCGAN is significantly improved compared with the traditional expansion method，which is suitable for expanding crack images.

Key words： deep convolution generative adversarial network；data argumentation；crack image；spectral normalization；activation function

0　引言

随着我国陆路交通事业的快速发展，公路和铁路建设的桥梁、隧道数量急剧增长。现代桥梁、隧道结构大多由混凝土制成，随着时间的推移，这些混凝土表面经常会形成不同结构和形状的裂缝，它们直接反映了其病害程度，因此定期进行裂缝检测对于保证桥梁和隧道安全具有重要意义[1]。传统上，裂缝是通过工程技术人员的目视检查来识别，识别过程主观且低效[2]。近年来，深度学习技术在图像分类识别领域取得了较大的突破[3]，许多学者将卷积神经网络算法应用于裂纹检测，大大提高了裂纹检测的效率和准确性。但由于裂缝产生的位置和环境

收稿日期：2022－03－28.

基金项目：国家自然科学基金面上项目(62076123).

* **通信作者：**谢永华　**E-mail：**2605764844@qq.com

比较复杂，通过传统采集方法获得的有效样本数普遍较少。深度学习需要大量的训练样本来保证卷积神经网络的分类性能，过低的样本数容易产生过拟合而导致无法训练与学习等问题。因此，在训练样本数不足的情况下，需要通过算法对样本数据进行有效扩充[4]。

实际应用中图像样本扩充一般通过几何变换、色彩抖动、添加噪声等方法来实现数据增广。Yu等[5]通过把图像沿水平尺寸翻转、移位以及随机角度旋转的随机扰动方式来生成数据，扩充样本数据。González等[6]在训练的过程中对图像采取缩放、裁剪和扭曲来扩充样本数据集传输到神经网络进行分类。Huang等[7]通过综合运用翻转、旋转与抠取的方法，首先对采集到的裂纹图像以随机角度旋转，接着在旋转图上用滑动窗口截取生成子图像，以此扩充训练数据集。这些方法虽然扩充了样本数量，但是样本质量并没有提高，数据分布单一，在一些动态和不平稳实际应用场景难以奏效。Frid-Adar等[8]提出了使用生成对抗网络(Generative Adversarial Network，GAN)生成增广图像，通过随机噪声学习真实数据集的样本分布，有效地生成了新的样本数据。自GAN被提出以来，产生了诸多变体，深度卷积生成对抗网络(Deep Convolutional Generative Adversarial Network，DCGAN)是其中较好的一种，广泛应用于图像数据集扩充领域。谈爱玲等[9]使用DCGAN对拉曼光谱样本进行扩充，识别率得到明显提高。戚永军等[10]使用DCGAN成功实现了肺结节图像的数据扩充。但是传统DCGAN会出现模型容量有限、梯度消失，以及生成样本特征不明显等问题，导致模型在实际训练过程中难以稳定进行，无法大规模扩充训练样本来保证卷积神经网络的分类性能。

基于以上原因，本文提出了一种基于改进深度卷积生成对抗网络的裂缝样本扩充方法，在训练过程中首先对原始数据集进行预处理，利用滑窗法进行数据降维和清洗，提升输入图像的质量。然后，通过优化传统DCGAN网络激活函数保留生成的裂缝图像细节，在网络结构中引入谱归一化增加训练模型的稳定性，构建改进深度卷积生成对抗网络(MDCGAN)模型进行样本扩充，最后将扩充后的混合样本输入到Alexnet网络中。通过与传统扩充方法的实验对比结果论证了本文方法在小样本裂缝图像识别领域的有效性。

1 改进深度卷积生成对抗网络

常用的小样本裂缝识别模型如图1所示。首先对裂缝数据集进行预处理，通过构建的MDCGAN模型生成对桥梁裂缝图像进行增广，将扩充样本和原始样本的混合数据集输入到Alexnet模型进行训练和分类，实现裂缝识别。

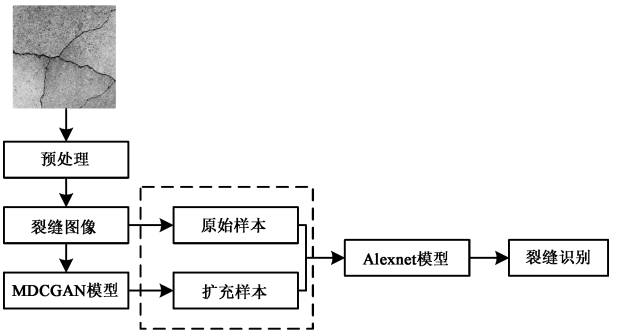


图1 小样本裂缝识别模型

1.1 基于滑窗法的裂纹图像预处理

由于实际采集的裂缝图像分辨率普遍较高，使用高分辨率的输入图像通常会受到DCGAN网络的限制，超过网络指定阈值的图像会按一定比例缩放[11]。随着图像的整体缩放，原始图像中大部分与裂纹图像无关的背景面元信息会成为压缩图像的主要部分，而由于裂缝图像本身信息量很少，压缩后会造成裂纹特征信息丢失，从而会降低后续的训练和识别效率。为此，本文通过引入滑窗法进行图像预处理。

对于数据集中的裂缝图片，使用自定义$W\times H$的固定大小窗口对其进行滑动切片，具体步骤如下式所示：

$$\begin{aligned}\mathrm{img}\,L_x &= m\times W\\ \mathrm{img}\,L_y &= n\times H\end{aligned}\tag{1}$$

$$\begin{aligned}\mathrm{img}\,R_x &= (m+1)\times W\\ \mathrm{img}\,R_y &= (n+1)\times H\end{aligned}\tag{2}$$

$$\begin{aligned}m &= \mathrm{srcIm}\,g_{\mathrm{w}}/W\\ n &= \mathrm{srcIm}\,g_{\mathrm{h}}/H\end{aligned}\tag{3}$$

其中，W和H为滑动窗口的宽和高；$\mathrm{img}\,L_x$，$\mathrm{img}\,L_y$，$\mathrm{img}\,R_x$和$\mathrm{img}\,R_y$分别代表滑窗截取面元的左上角横坐标、左上角纵坐标、右下角横坐标和右下角纵坐标；$\mathrm{srcIm}\,g_{\mathrm{w}}$和$\mathrm{srcIm}\,g_{\mathrm{h}}$分别为原始裂缝图像的宽和高[12]；$m$和$n$的计算公式如(3)所示。本文数据集原始尺寸为1 024×1 024像素，设W和H均为64像素，滑窗法对数据集进行扩充如图2所示。

从图中可以看出，用滑窗法生成的子数据集中存在一些背景面元图像和一些裂缝占比很小的图像，而用 DCGAN 生成趋于真实的裂缝图像，需要尽可能保留原始数据集的裂缝图像特征信息，因此需要对生成的子图数据集进行清洗。本文采用模型清洗和人工清洗两者相结合的方法，使用 Alexnet 对子数据集做一个粗分类，以此清洗大量的背景面元图像，接着人工清洗出裂缝占比小的裂缝图像。

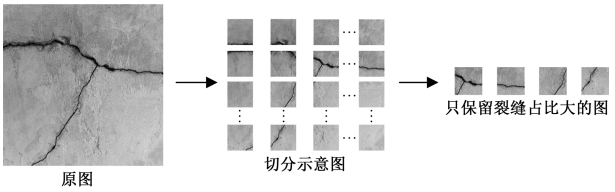


图 2　滑窗法对图片进行扩充示意图

1.2　改进的 MDCGAN 网络模型

深度卷积生成对抗网络 DCGAN[13] 是由 Alec Radford 提出的，其基本思想是在生成对抗网络 GAN 的基础上增加卷积神经网络。DCGAN 由生成器 G 和判别器 D 构成，根据对抗思想，两者相互博弈，最终达到纳什均衡。

图 3 为传统的 DCGAN 基本结构。其中 z 为输入生成器的随机噪声，$G(z)$ 为经过生成模型得到的伪造数据，判别模型获得 $G(z)$ 后将其与真实数据 x 进行比较，进行真假判断并将结果反馈给生成器，整个过程可用一个二元极小极大博弈来描述，目标函数如式(4)所示：

$$\min_G \max_D V(D,G)=E_{x\sim p_{\text{data}}(x)}[\log(D(x))]+E_{z\sim p_g(z)}[\log(1-D(G(z)))] \tag{4}$$

$V(D,G)$ 是二分类任务中交叉熵损失，训练网络 D 最大化 $\log(D(x))$，即最大化正确判断数据真伪的概率，训练网络 G 最小化 $\log(1-D(G(z))$，即最大化判别 D 的损失函数，$p_{\text{data}}(x)$ 为真实数据的分布，$p_g(z)$ 为噪声分布。在训练过程中，p_g 会逐渐收敛至数据的真实分布 p_{data}，此时模型达到纳什均衡状态，生成器拥有拟合真实数据分布的能力。

与其他生成对抗网络算法相比，传统 DCGAN 在稳定性和生成样本质量上具有一定优势，但是由于裂纹图像的稀疏性特征使得传统的 DCGAN 网络在训练时会出现梯度消失、生成样本特征不明显等问题。因此，本文对传统 DCGAN 网络进行改进，通过激活函数改进和引入谱归一化构建 MDCGAN 网络。

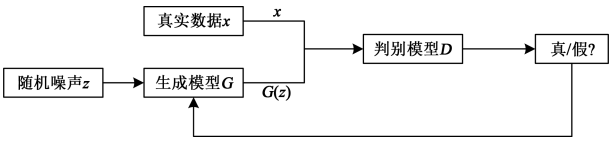


图 3　DCGAN 基本结构

1.2.1　激活函数改进

为了缓解网络训练中出现的梯度消失现象，Nair 提出了修正线性单元 ReLU(Rectifier Linear Units)，该应用减少了网络训练的时间，同时也提高了模型的识别率。但是在原始 DCGAN 网络中，ReLU 激活函数的主要功能是完成卷积层的非线性激活，过滤了小于 0 的输入，如果输入为负数时，会出现梯度消失，导致激活函数关闭，输入参数得不到更新。为此，本文采用了 SeLU(Self-Normalizing Neural Networks)激活函数，能够保留小于 0 的计算且提供的特征比较丰富；经过该激活函数后的样本会自动归一化到 0 均值和单位方差，从而保证训练过程中梯度不会爆炸或消失。公式如式(5)所示：

$$\text{SeLU}=\lambda\begin{cases}x & x>0\\ \alpha(e^x-1) & x\leqslant 0\end{cases} \tag{5}$$

此外，由于 SeLU 保留了小于 0 的输入，这会导致前向传播和后向传播的计算时间延长，模型优化的难度将进一步增加。为了获得更丰富的特征且不增加计算的时间，MDCGAN 网络只在生成网络中使用此激活函数。

1.2.2　谱归一化

传统 DCGAN 网络普遍存在训练稳定性不高，针对训练过程中模型卷积网络存在参数振荡问题，通常是对参数矩阵元素加以限制，不让其大于限定的值。这种方法虽简单有效，但同时带来参数矩阵不稳定的问题。研究发现，谱归一化(Spectral Normalization，SN)的权重标准化技术可以很好地平衡这个问题，在保证满足 Lipschitz 条件的同时，又不破坏网络中的参数矩阵结构[14]。其核心思想是用每层的网络参数与参数矩阵的谱范数相除，达到 Lipschitz 等于 1 的条件，公式如式(6)所示：

$$\overline{W}_{\text{SN}}(W):=\frac{W}{\sigma(W)} \tag{6}$$

式中，$\sigma(W)$ 为权重 W 的二范式。为了满足 Lipschitz 连续且维持参数矩阵的稳定性，从而产生更高质量的图片，提出引入谱归一化解决训练波动的现象。

1.2.3 模型与算法

如图 4 所示为 MDCGAN 的模型训练结构，其生成网络细节和判别网络细节如表 1 和表 2 所示。

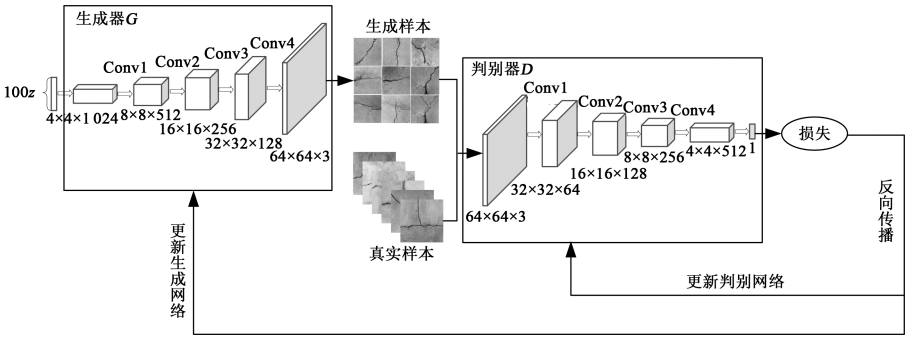


图 4 MDCGAN 训练模型

表 1 MDCGAN 生成网络细节

网络层	卷积核	步长	激活函数	是否有 SN
输入层	4×4	0	SeLU	否
Conv1	5×5	2	SeLU	是
Conv2	5×5	2	SeLU	是
Conv3	5×5	2	SeLU	是
Conv4	5×5	2	SeLU	是
输出层	5×5	2	tanh	否

表 2 MDCGAN 判别网络细节

网络层	卷积核	步长	激活函数	是否有 SN
输入层	5×5	2	LeakyRelu	否
Conv1	5×5	2	LeakyRelu	是
Conv2	5×5	2	LeakyRelu	是
Conv3	5×5	2	LeakyRelu	是
Conv3	5×5	2	LeakyRelu	是
输出层	4×4	0	LeakyRelu	否

MDCGAN 算法伪代码如下，▽表示梯度算子，其中 s_steps 和 k_steps 是超参数，k_steps 为判别器的训练次数，多次更新判别器来保持两个网络的训练平衡。

1) for s_steps do：

2) for k_steps do：

3) 在真实样本 $p_{\text{data}}(x)$ 中采用 m 个真实样本 $\{x^{(1)},\cdots,x^{(m)}\}$

4) 在噪声分布 $p_{\text{G}}(z)$ 中采样 m 个噪声样本 $\{z^{(1)},\cdots,z^{(m)}\}$

5) 根据梯度更新判别器：

6) $\nabla_m \frac{1}{m}\sum_{i=1}^{m}\{\log D(x^{(i)})+\log\{1-D[G(z^{(i)})]\}\}$

7) end for

8) 在噪声分布 $p_{\text{G}}(z)$ 中采样 m 个噪声样本 $\{z^{(1)},\cdots,z^{(m)}\}$

9) 根据梯度更新生成器：

10) $\nabla_m \frac{1}{m}\sum_{i=1}^{m}\log\{1-D[G(z^{(i)})]\}$

11) end while

2 特征提取与识别

裂缝识别过程包括裂缝特征的提取和分类，将原始样本和扩充后的样本添加到 Alexnet 模型中进行自动提取裂缝特征并分类。本文以 Alexnet 网络模型为骨干网络，采用迁移学习的技术，利用 ImageNet 上预训练得到的权重作为初始参数，更改模型的全连接层和输出层，微调后进行裂缝特征的提取和分类。由于裂纹图像识别是关于有无裂缝的二分类问题，修改 Alexnet 的 fc2 层输出神经元个数为 1 024 和 fc3 层的输出神经元个数为 2 个，并针对模型容易出现过拟合问题，在最后一个池化层和 fc2 全连接层加入 dropout 层，并设置 dropout 率为 0.3，改进后的 Alexnet 模型结构如图 5 所示，由 5 个卷积层和 3 个全连接层组成。

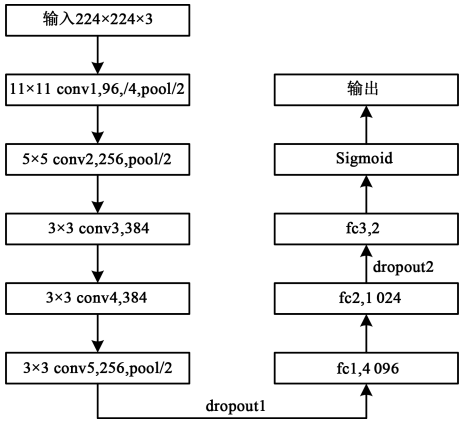


图 5 改进的 Alexnet 模型结构图

3　实验与分析

3.1　数据集与实验环境

采用陕西师范大学李良福教授团队公开的 2 068 张桥梁裂缝图像作为数据集[12]，部分样本如图 6 所示。软件环境：tensorflow-gpu1. 13. 2，keras2. 1. 5，numpy1. 17. 4，python3. 6。硬件环境：GPU 是 NVIDIA Quadro M4000，通过 CUDA10. 0 与 cudnn7. 4. 1. 5 的组合进行加速运算，主频为 2. 10 GHz，内存为 32 G。

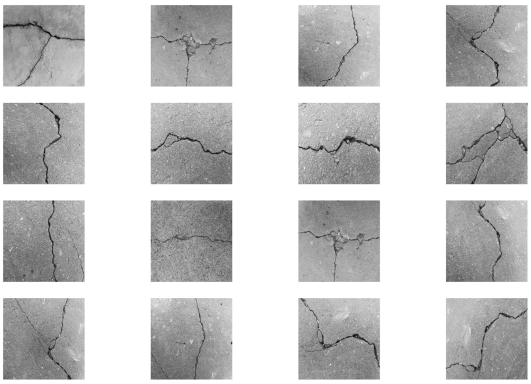


图 6　桥梁裂缝图像示例

3.2　生成样本评价指标

采用 IS(Inception Score)指标对生成的桥梁裂缝图像进行定量分析，将生成图像放入 Inception 模型中，利用求得的熵对生成样本的质量进行评估，如式(7)所示。

$$IS=\exp(E_x KL(p(y\mid x)\|p(y))) \tag{7}$$

式中，x 为生成的桥梁裂缝图像，y 为生成样本输入到模型转换的向量，KL 为散度。

3.3　图像识别模型和评估指标

实验采用改进的 Alexnet 卷积神经网络模型，并对模型进行微调，训练的初始化权值设置 epoch 为 0，学习率设为 0. 000 5，每个批次 64 个样本，训练世代设为 150。本实验中正样本为包含原始桥梁裂缝图像和生成图像的混合样本集，其他环境照片、桥梁背景面元等照片都称为负样本，如图 7 所示。加入负样本的目的是让其本身的复杂特征能够充分混淆分类器，从而更能说明分类器的鉴别能力。本实验是关于有无裂缝的二分类实验，采用混淆矩阵法表示桥梁裂缝的分类情况，如表 3 所示。使用准确率(Accuracy，ACC)、特异性(Specificity，SPE)和灵敏度(Sensitivity，SEN)作为裂缝识别评估指标。



(a) 桥梁背景面元样本　(b) 桥梁路面样本　(c) 桥梁周边环境样本

图 7　负样本种类的示例图

表 3　混淆矩阵法表示样本分类情况表

类别	被分类为正样本	被分类为负样本
数据为正样本	TP (True Positive)	FN (False Negative)
数据为负样本	FP (False Positive)	TN (True Negative)

其中，准确率 ACC、特异性 SPE 和灵敏度 SEN 指标[15]的计算公式如下：

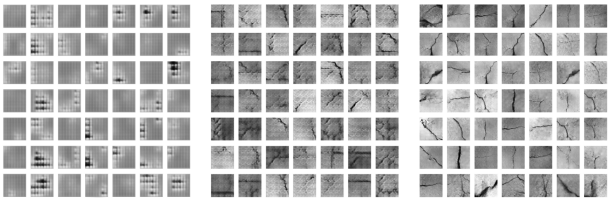
$$ACC=\frac{TN+TP}{TP+FP+TN+FN} \tag{8}$$

$$SPE=\frac{TN}{TN+FP} \tag{9}$$

$$SEN=\frac{TP}{TP+FN} \tag{10}$$

3.4　实验结果与分析

为了更好地训练神经网络，需要对模型的权值进行初始化。MDCGAN 模型的学习率为 0. 000 2，批处理大小设为 64，输入到生成器的是长度为 100 的正态分布随机数，使用的是 Adam 优化器，保存检查点之间的间隔为 50，多次实验对比后得知，在迭代 1 000 次以后模型的损失函数震荡幅度较大，很不稳定，模型容易发生崩溃，从而将 MDCGAN 的训练世代设为 1 000。图 8 为生成样本在第 1，500，1 000 个 Epoch 生成样本的情况，从图中可以看出，随着 Epoch 次数的增加，生成的裂缝样本图像的轮廓越来越清晰，特征更加明显。



(a)　1 Epoch　(b)　500 Epoch　(c)　1 000 Epoch

图 8　MDCGAN 生成样本图

计算原始数据集、传统物理扩充方法[7]、传统 DCGAN 方法[16]以及本文方法生成的样本 IS 值如表 4 所示。IS 值越高表明生成的图像质量越好。

结果显示，原始裂缝数据集的 IS 值为 1.02，传统扩充方法的 IS 值和 DCGAN 的 IS 值均低于本文方法的 IS 值。

表 4 IS 值比较

数据扩充方法	IS 值
原始数据集	1.02
传统物理扩充方法	0.63
传统 DCGAN 方法	0.71
本文方法	0.78

使用本文方法生成裂缝图像并加入原始数据集构成正样本共 12 408 张，负样本数据有 12 000 张，正负样本按照 9∶1 进行随机选取划分为训练集和验证集，为了形成对比，用传统的翻转、缩放、调整饱和度等扩充样本实验中，按同等比例进行扩充和划分，测试集从正负样本中随机选取 1 000 张（正样本 100 张，负样本 900 张），然后分别使用 Alexnet 卷积神经网络模型进行训练和测试。实验结果对比如表 5。通过多次实验，记录每次模型训练完成后图像分类的准确率，并选择准确率最高的一次作为评估模型识别性能的依据，由于原始样本有限且 Alexnet 网络训练需要大量样本，Dropout 层在过拟合上有一定的抑制作用，仅达到 78.6%的准确率，DCGAN 的引入将裂缝识别准确率由 78.6%提升到了 93.9%，本文提出的改进模型进一步将准确率提高到了 95.5%，高于传统扩充方法的 90.7%准确率。结果表明，本文扩充方法优于传统的翻转、缩放变化的数据扩充方法，图像的识别准确率有所提高，主要原因是本文方法适用于裂缝图像的稀疏分布特性，并且裂缝病害图像属于小样本无监督学习范畴的问题，通过 MDCGAN 提取少量裂缝样本特征并实现重构，解决了训练样本的不足和特征不平衡的问题，生成了更多的样本，保证了卷积神经网络的分类性能。而传统方法只是扩充了样本数量，并没有提高样本质量，训练样本和测试样本来自相同的特征空间。

表 5 不同方法结果对比

数据扩充方法	SPE/%	SEN/%	ACC/%
原始数据集	72.5	74.1	78.6
传统物理扩充方法	86.2	88.6	90.7
传统 DCGAN 方法	90.6	94.5	93.9
本文方法	94.7	96.3	95.5

使用本文方法在不同样本扩充系数上进行实验，对裂缝的分类识别准确率对比如图 9 所示。样本扩充系数为 0～6 倍时，随着训练样本的增加以及 Dropout 层的使用，逐步解决了 Alexnet 深度网络的过拟合问题，裂缝的分类效果改善明显，当扩充系数为 6 时，识别准确率达到最高值 95.5%。继续扩充裂缝图像样本，当扩充系数为 6～15 倍时，识别准确率没有继续提高，达到饱和状态。由于小样本裂缝图的特征有限，扩充更多的样本无法继续提高分类效果。

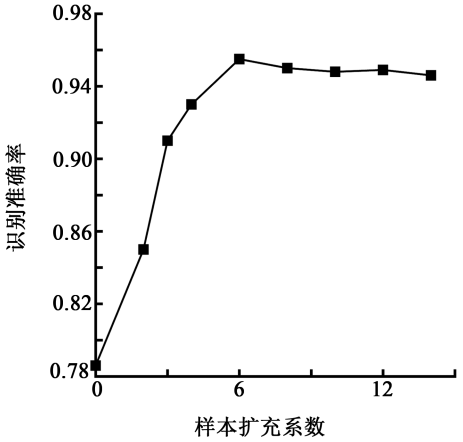


图 9 不同样本扩充系数的识别准确率分布

4 结论

从样本扩充的角度，提出基于改进深度卷积生成对抗网络的裂缝样本扩充方法，能解决样本少产生的过拟合而无法训练等问题。结果表明，本文方法适用于裂缝图像的小样本扩充，不仅克服了传统方法导致样本特征空间不足的局限性的问题，还解决了现有 DCGAN 方法在小样本扩充过程中的不理想问题，提高了生成图像的细节和模型的稳定性，识别准确率也有所提升。

参考文献：

[1] Li G, Liu Q, Zhao S, et al. Automatic crack recognition for concrete bridges using a fully convolutional neural network and naive Bayes data fusion based on a visual detection system[J]. Measurement Science and Technology, 2020, 31(7): 075403.

[2] Jza B, Js A. Weakly supervised network based intelligent identification of cracks in asphalt concrete bridge deck-ScienceDirect[J]. Alexandria Engineering J., 2020, 59(3): 1307-1317.

[3] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.

[4] Kim Y, Kwak G H, Lee K D, et al. Performance evaluation of machine learning and deep learning algorithms in crop classification: Impact of hyper-parameters and training sample

size[J]. Korean J. of Remote Sensing, 2018, 34(5): 811-827.

[5] Yu X, Wu X, Luo C, et al. Deep learning in remote sensing scene classification: a data augmentation enhanced convolutional neural network framework[J]. GI Science & Remote Sensing, 2017, 54(5): 741-758.

[6] González R E, Munoz R P, Hernández C A. Galaxy detection and identification using deep learning and data augmentation [J]. Astronomy and Computing, 2018, 25: 103-109.

[7] Huang H W, Li Q T, Zhang D M. Deep learning based image recognition for crack and leakage defects of metro shield tunnel-ScienceDirect[J]. Tunnelling and Underground Space Technology, 2018, 77: 166-176.

[8] Frid-Adar M, Diamant I, Klang E, et al. GAN-based synthetic medical image augmentation for increased CNN performance in liver lesion classification[J]. Neurocomputing, 2018, 321(10): 321-331.

[9] 谈爱玲，楚振原，王晓斯，等. 基于拉曼光谱和 DCGAN 数据增强的珍珠粉掺伪检测研究[J]. 光谱学与光谱分析，2022，42(3)：769-775.

Tan Ailing, Chu Zhenyuan, Wang Xiaosi, et al. Detection of pearl powder adulteration based on Raman spectroscopy and DCGAN data enhancement [J]. Spectroscopy and Spectral Analysis, 2022, 42(3): 769-775.

[10] 戚永军，顾军华，栗位勋，等. 基于生成对抗网络的肺结节图像数据增强方法[C]//中国计算机用户协会年第二十三届网络新技术与应用年会论文集，2019：199-203.

Qi Yongjun, Gu Junhua, Li Weixun, et al. A method for lung nodule image data enhancement based on generative adversarial network[C]// Proc. of Twenty-third Annual Conf. on New Technologies and Applications of Networks, 2019, China Computer Users Association, 2019: 199-203.

[11] 吴　雪，宋晓茹，高　嵩，等. 基于深度学习的目标检测算法综述[J]. 传感器与微系统，2021，40(2)：4-7，18.

Wu Xue, Song Xiaoru, Gao Song, et al. Review of target detection algorithms based on deep learning[J]. Transducer and Microsystem Technologies, 2021, 40(2): 4-7, 18.

[12] 李良福，马卫飞，李　丽，等. 基于深度学习的桥梁裂缝检测算法研究[J]. 自动化学报，2019，45(9)：1727-1742.

Li Liangfu, Ma Weifei, Li Li, et al. Research on detection algorithm for bridge cracks based on deep learning[J]. Acta Automatica Sinica, 2019, 45(9): 1727-1742.

[13] Wang J, Yi G, Zhang S, et al. An unsupervised generative adversarial network-based method for defect inspection of texture surfaces[J]. Appl. Sciences, 2020, 11(1): 283.

[14] 颜　贝，张建林. 基于谱约束的生成对抗网络图像数据生成研究[J]. 半导体光电，2019，40(6)：896-901.

Yan Bei, Zhang Jianlin. Image data generation based on generative adversarial network [J]. Semiconductor Optoelectronics, 2019, 40(6): 896-901.

[15] Il B, Ayyldz H, Tuncer T. Discrimination of β-thalassemia and iron deficiency anemia through extreme learning machine and regularized extreme learning machine based decision support system [J]. Medical Hypotheses, 2020, 138: 109611.

[16] Dewi Christine, Chen Rung-Ching, Liu Yan-Ting, et al. Synthetic data generation using DCGAN for improved traffic sign recognition [J]. Neural Computing and Applications, 2021: 1-16.

作者简介：

谢永华(1976—)，男，江苏省人，教授，博士生导师，主要研究方向为模式识别与图像处理；

齐　杨(1993—)，男，安徽省人，硕士研究生，主要研究方向为图像处理。