



· 可视化检测技术 ·

基于 DCGAN 数据集增强的 ECT 系统 流型识别技术改进

胡红利¹, 王茂杰¹, 杨姝楠^{1,2}, 杨海潮¹, 卢家宇¹

(1. 西安交通大学 电力设备电气绝缘国家重点实验室, 陕西 西安 710049; 2. 北京机械设备研究所, 北京 100854)

摘要 基于电容层析成像(electrical capacitance tomography, ECT)系统的流型识别技术具有非侵入性和可视化的优点,被广泛应用于各种工业过程的动态测量中。为提高 ECT 系统的流型识别准确率,基于神经网络模型的识别算法被广泛应用,但 ECT 系统难以获得大量实测样本,从而导致识别准确率低、模型泛化性差。针对这一问题,该文采用了基于深度卷积生成对抗网络(DCGAN)的数据集扩增方法,利用经过预处理的 LSSVM 方法重建所得的图像,搭建基于 DCGAN 的流型图像生成模型进行实验,并利用 GAN-train 和 GAN-test 两个客观指标对生成图像进行评价,之后使用扩增后的数据集进行基于 YOLOv3 的流型识别。实验结果表明,利用 DCGAN 方法能够有效扩增原有数据集,生成图像准确度高、丰富性强,配合 YOLOv3 的目标检测算法,可以对 ECT 系统的流型识别准确率提升有较大幅度的改进。

关键词 流型识别;数据集扩增;机器学习;深度卷积生成对抗网络;YOLOv3

中图分类号: TP-391 **DOI:** 10.16152/j.cnki.xdxbr.2023-04-006

Improvement of flow pattern identification technology for ECT system based on DCGAN dataset enhancement

HU Hongli¹, WANG Maojie¹, YANG Shunan^{1,2}, YANG Haichao¹, LU Jiayu¹

(1. State Key Laboratory of Electrical Insulation and Power Equipment, Xi'an Jiaotong University, Xi'an 710049, China;

2. Beijing Research Institute of Mechanical Equipment, Beijing 100854, China)

Abstract The flow pattern recognition technology based on capacitive tomography (ECT) system is widely used in dynamic measurement of various industrial processes due to its non-invasive and visual advantages. To improve the flow pattern identification accuracy of ECT system, recognition algorithm based on neural network model is widely used. But the ECT system can't get a lot of ECT system measured samples, resulting in low accuracy, low model generalization. To solve this problem, this paper adopted the dataset amplification method based on deep convolution generative adversarial network (DCGAN), and used the images reconstructed by the preprocessed LSSVM method to build a flow pattern image generation model based on DCGAN for experiments. Gan-train and GAN-test were used to evaluate the generated images. After that, the amplified dataset is used for flow pattern identification based on YOLOv3. The experimental results show that the DCGAN method can effectively amplify the original data set and generate images with high accuracy and richness. Together

收稿日期: 2022-12-15

基金项目: 国家自然科学基金(52177009); 陕西省科技攻关项目(2016GY001)

第一作者: 胡红利, 男, 教授, 博士生导师, 从事检测测试与计量技术研究, hlhu@mail.xjtu.edu.cn。

with the target detection algorithm of YOLOv3, the flow pattern recognition accuracy of ECT system can be improved to a great extent.

Keywords flow pattern identification; data set amplification; machine learning; deep convolution generative adversarial network; YOLOv3

流型的准确测量在工业生产中有极为重要的作用。基于电容层析成像(ECT)系统的流型识别技术因具有非侵入性和可视化的优点,被广泛应用于各种工业过程的动态测量中。随着机器学习理论的高速发展,目前使用较为广泛的流型识别方法使用神经网络^[1-3]作为识别模型。王莉莉等人将 RBF 神经网络用于流型识别问题,在仿真测试的条件下,各流型识别准确率都达到 85% 以上^[4];宋蕾等人使用局部回归网络 Elman 进行流型辨识,对 7 种流型的仿真样本进行测试,与传统 BP 神经网络测试结果相对比,识别准确率由 72% 提升至 82%^[5];张立峰等人基于遗传算法优化的极限学习机算法进行流型识别,在静态模拟实验下,平均识别准确度可以达到 90% 以上^[6]。神经网络的训练需要有大量的模型样本,但通过 ECT 系统获得的实测样本非常有限,难以支撑模型训练,不能满足真正工业上的需求。对实测样本进行数据集扩增,利用扩增后的样本进行模型训练,这样才能让深度学习模型发挥作用。因此,如何将实测样本进行数据集增强扩增有着十分重要的意义。

对图像数据集进行增强扩增可以解决实测样本缺乏的问题,进而提升识别模型的识别准确率。数据增强一般分为有监督的数据增强和无监督的数据增强两种。其中,有监督的数据增强是在不改变标签的条件下,使用预设的某种变换规则。有监督的数据增强分为针对单样本和多样本两种进行操作,Xie 等人研究了单样本数据增强方法,通过几何变换和色彩空间变换进行数据集的增强^[7]。几何变换是对单张图片进行翻转、旋转、缩放等操作,色彩空间变换是对单张图片的对比度、亮度、饱和度等进行操作。针对多样本的数据增强,Nazki 等人通过样本比较的方法,利用现有样本直接合成新样本完成数据增强^[8]。但利用传统的有监督式数据扩增方法扩增后的数据集信息量有限,无法形成较为准确的数据集,不适用于 ECT 系统。

针对上述问题,本文搭建了基于深度卷积生成对抗网络的无监督式流型数据集增强模型,利

用生成模型生成“以假乱真”的流型图像,对重建图像集进行扩增,扩增后的数据集用以支持识别模型训练,以提高其性能与泛化能力,使用基于 YOLOv3 的流型识别方法,可以大幅度提高 ECT 系统的流型识别准确率。

1 深度卷积生成对抗网络

DCGAN 是 Radford 等人在 2016 年提出的一种 GAN 的改进模型^[9]。将 CNN 应用于 GAN,用卷积层替换原有的多层感知机 MLP,并据此对其他部分进行相应改进,有效解决了原有模型训练不稳定的问题。通过使用卷积层捕获的特征来进行图像分类,使得 GAN 有了更好的表达能力,更适用于图像样本的处理。相比于 GAN,DCGAN 的改进主要有以下几点。

1) 使用卷积层代替池化层。去掉池化层后整个网络变为可微,便于 DCGAN 的训练。在判别器上使用步幅卷积层(stride convolutions)实现下采样,通过卷积提取图像特征,并减少每层特征图的维度。在生成器上使用转置卷积(deconvolution)实现上采样,逐层提高生成图像分辨率。

2) 只保留生成器首层及判别器末层,去除其他全连接层。

3) 使用批量归一化层^[10]。

4) 生成器的输出层采用 Tanh 激活函数以约束生成图像的范围,其他层采用 ReLU 函数。

在 DCGAN 的原始模型中,生成器的结构如图 1 所示,由一个全连接层和 4 个转置卷积层组成。输入是一个 100 维的高斯随机噪声,其服从范围在 $[-1, 1]$ 的均匀分布,通过全连接层并对向量进行 reshape 操作,将其扩展为 1 个 $4 \times 4 \times 1024$ 的特征向量。从第 2 层开始,一共经过 3 个卷积层,利用转置卷积作上采样,每次操作的卷积核大小为 5×5 ,步长为 2。每经过 1 个转置卷积层,特征向量尺寸变为之前 2 倍,通道数变为原来的 1/2。但经过最后一个卷积层后,其向量维度变为 $64 \times 64 \times 3$,即输出一个 64×64 大小的三通道 RGB 图像。通过生成器完成了随机噪声到三

通道图像的转化。




图 1 DCGAN 生成器结构

Fig. 1 DCGAN generator structure

判别器的结构即为生成器结构的反向,其输入为 1 个 $64 \times 64 \times 3$ 的特征向量,先通过 1 个卷积层恢复成 $32 \times 32 \times 64$ 的向量。之后每经过 1 个卷积层,特征向量尺寸变为之前 $1/2$,通道数增加 1 倍,最后,由 1 个全连接层输出 1 个概率值标量,即输入样本的真假概率值。

2 基于 DCGAN 的流型数据集增强

本文将介绍利用搭建的 DCGAN 模型进行 4 种流型图像生成的实验。基于 DCGAN 的流型数据集增强实验流程如图 2 所示。




图 2 基于 DCGAN 的流型数据集增强流程图

Fig. 2 Flow data set enhancement flow chart based on DCGAN

2.1 实验环境及数据集搭建

整体 DCGAN 网络模型的搭建与模型训练基于 Tensorflow 深度学习架构。Tensorflow 使用结点(nodes)和线(edges)组成的数据流图来描述数学计算,其中大小可动态调整的多维数组称为张

量。硬件采用 Intel Core i7,32 GiB 内存的处理器进行实验。

本文的原始数据集是通过最小二乘支持向量机法(LSSVM)得到的 240 个重建图像,对于 DCGAN 的训练来说,数据集数量略少,训练时容易产生欠学习、过拟合的问题,因此,要对流型图像进行预处理。之所以可以利用 LSSVM 方法对原始图像进行扩充,是因为 DCGAN 的特定结构,即结合了 GAN 与 CNN 两种神经网络。CNN 中的卷积和池化操作使得其可以在很大的空间范围内处理上下文和整合特征,即具有旋转不变性和平移不变性^[11]。

对核心流、环形流、偏心流的图像分别都旋转 90° 、 180° 、 270° 后,各得到 180 张图片;对层状流的图像经过翻转 180° 及左右各平移 3 个像素,得到 180 张图片。扩充后的数据集加上原有图像(通过 LSSVM 生成每种流型 60 张)共同构成真实图像集,每种流型各 240 张,4 种流型共 960 张。且将原来 100×100 的图像利用 Matlab 等比例缩小为 96×96 。将真实图像集中的 80% 设定为训练集,其余的 20% 设定为验证集。由于是随机选取,则训练集和验证集中每种流型图像数并不平均,最终数据集构成如表 1 所示。

表 1 DCGAN 实验数据集构成

Tab. 1 DCGAN experimental data set construction

数据集	核心流		偏心流		层状流		环形流	
	重建	旋转	重建	旋转	重建	翻转	重建	旋转
训练集	43	149	38	154	37	155	22	170
验证集	17	31	22	26	23	25	38	10

2.2 基于 DCGAN 的数据集增强模型架构

用于流型图像的 DCGAN 生成器结构如图 3

所示。共使用 5 层转置卷积层,前 4 层用 ReLU 激活函数,最后 1 层使用 Tanh 激活函数。在 BN 层对数据进行批量归一化处理,以解决梯度爆炸的问题。判别器的结构几乎可以认为是生成器的逆结构(从右向左看),区别只在于使用的激活函数和最终输出。前 4 层用于提取特征,激活函数

采用 Leaky-ReLU 函数,最后 1 层用于输出判别结果,使用 Sigmoid 激活函数。

采用目前 DCGAN 模型常用的 SGD 优化算法^[12-14]和 Adam 优化算法^[12-14]进行实验,对结果进行对比分析如下。




图 3 用于流型图像的 DCGAN 生成器结构图
Fig.3 DCGAN generator structure diagram for streaming images

1)训练过程中 Loss 值。与使用 SGD 优化算法训练的损失函数相比,Adam 优化算法下的损失函数更小。Adam 算法下的判别器 Loss 值最大不超过 2,模型稳定时最低可达 0.45,而 SGD 算法下的判别器 Loss 值最高达到 4.5,且最小值也大于 0.8。除去两个实验最后损失激增的部分,Adam 算法下的生成器 Loss 值主要变化在 0.1 ~ 2,而 SGD 算法下的生成器 Loss 值变化在 1 ~ 3。则从损失函数来看,相较于 SGD 优化算法而言,Adam 优化算法训练的结果更好。

2)生成图像视觉效果。由于 DCGAN 方法是随机生成流型图像,并不能指定生成图像的流型尺寸。因此,从 2 种优化算法下的生成图像中,每种流型选择 1 个代表样例,则 2 个实验中生成的不同流型样本图像如表 2 所示。

根据上述结果的对比分析可以得知,使用 Adam 优化算法生成的图像效果更好。因此,利用 Adam 实验中训练好的模型进行流型图像生成实验,最终得到每种流型 1 500 个图像,4 种流型共 6 000 个图像,相较于重构得到的 240 个图像,数据集得到了 25 倍的扩增,生成的部分图像如图 4 所示。

表 2 使用 2 种优化算法的真实与生成图像示例
Tab.2 Examples of real and generated images using two optimization algorithms

流型	算法		
	真实重建图像	使用 Adam 算法的生成图像	使用要 SGD 算法的生成图像
层状流			
核心流			
环状流			
偏心流			




图 4 扩增数据集中生成的部分流型示意图

Fig. 4 A partial flow pattern diagram generated in amplified data set

3 基于 GAN-train 与 GAN-test 的生成图像评估

对于 GAN-train 和 zGAN-test 这 2 个指标,我们都是利用成熟的神经网络作为分类器,通过测试真实图像和生成图像在分类器(classifier)上的表现来评估图像质量,其原理如图 5 所示。




图 5 GAN-train 与 GAN-test 实验原理图

Fig. 5 Schematic diagram of GAN-train and GAN-test experiments

首先,将 240 个真实图像的 85% 作为用于训练的真实图像训练集 Img_real_train ,15% 作为用

于验证的真实图像验证集 Img_real_test 。

1) GAN-train 是真实图像在利用生成图像训练过的分类器上的表现。先利用生成图像集 Img_gen 来训练初始分类器 Class_org ,固定后得到能有效分类生成图片的分类器 Class_gen ;然后,测试验证集 Img_real_test 在 Class_gen 的输出,即识别准确率。如果用于区分不同类别生成图像的分类器能够对真实图像进行正确分类,那么代表生成图像足够多样化,覆盖了真实图像所包含的每一个种类,使得分类器学习到真实图像足够多的相关特征。

2) GAN-test 是生成图像在利用真实图像训练过的分类器上的表现。先利用真实图像集 Img_real_train 来训练初始分类器 Class_org ,固定后得到能有效分类真实图片的分类器 Class_real ;然后,测试生成图像集 Img_gen 用 Class_real 的识别准确率。这个指标与图像精确率类似,GAN-test 值较高说明用于区分真实图像的分类器依然能辨别生成图像,这意味着生成的样本与真实的样本分布近似。

为评估本文设计的 DCGAN 架构生成的图像质量,利用基础变换扩充后的真实图像集,将其中的 80% 作为真实图像训练集 Img_real_train ,20% 作为真实图像验证集 Img_real_test 。选取上一节本文设计的 DCGAN 使用 Adam 算法训练时,最优情况下生成的 4 种流型图片,每种 1 500 个,共 6 000 个图像,作为生成图像集 Img_gen 。

用于识别图像的分类器选择成熟的 AlexNet^[15-17] 与 VGG-16^[18-20] 两种主流的深度卷积神经网络模型。GAN-train 与 GAN-test 评价得分表示的都是数据集在分类器上的识别准确度,将 4 次实验的平均值作为结果。

1) GAN-train 评价。首先,使用 Img_gen 作为训练集训练 2 个分类器,并调整分类器参数至识别准确率最优;而后测试验证集 Img_real_test 在训练好的分类器上的表现,即得到 GAN-train,结果如表 3 所示。

表 3 最优生成图像的 GAN-train 实验结果

Tab. 3 GAN-train experiment results for optimal image generation

单位:%

数据集	分类器模型	
	AlexNet	VGG-16
Img_real_test	93. 76	94. 48
GAN-train	91. 11	90. 67

如表 3 所示, GAN-train 的准确率与验证集 Img_real_test 的准确率都较高且相接近, 体现了生成图像的真实性, 且由于训练集是随机划分, 说明 DCGAN 产生的图像和训练集一样多样化, 较好地覆盖了真实图像的特征分布。

2) GAN-test 评价。首先, 使用 Img_real_train 作为训练集训练 2 个分类器, 并调整参数至最优, 然后测试 Img_gen 在训练好的分类器上的表现, 即得到 GAN-test, 结果如表 4 所示。

表 4 最优生成图像的 GAN-test 实验结果
Tab. 4 GAN-test experiment results for optimal image generation 单位: %

数据集	分类器模型	
	AlexNet	VGG-16
Img_real_train	46. 22	51. 56
GAN-test	40. 58	41. 17

如表 4 所示, 不论是训练集还是生成图像, 在分类器上的表现都并不理想, 识别准确率都不足 55%。虽然 GAN-test 值与标准值相差不大, 还是能一定程度上反映出生成图像与真实数据之间较为接近, 但 GAN-test 值与真实图像的识别准确率还是有一定差别。这是因为 Img_real_train 中包含的图像数量太少, 而所使用的分类器都是含有上亿参数的深层神经网络, 其含有的特征不足以被分类器完全捕捉。换言之, 真实图像训练集的信息量不足以训练分类器的参数, 这也说明了扩充数据集对于训练用于流型识别的深度神经网络是非常必要的。

4 基于 YOLOv3 目标检测算法的流型识别

YOLOv3 算法是一种 one-stage 的目标检测算

法, 与 two-stage 目标检测算法最大区别在运算速度上, YOLO 系列算法将图片划分成若干个网格, 再基于 anchor 机制生成先验框, 只用一步就生成检测框, 这种方法大大提升了算法的预测速度^[21-24]。YOLOv3 由 3 部分网络结构构成, 分别为主干特征提取网络、特征金字塔融合结构和预测结构, 主干特征提取网络采用 DarkNet53^[25] 的结构。YOLOv3 模型中, 卷积单元包含卷积、LeakyRelu 激活函数和批量标准化层。结构特征金字塔主要进行融合阶段, 将 DarkNet53 结构输出的 3 个有效特征层融合, 即通过上采样的方式将不同尺度的特征层进行拼接, 最终实现对于多尺度目标的检测。将融合后的 3 个加强特征层输入 Yolo Head 中进行预测分析, 对预测结果进行解码, 最终得出边界框的中心点坐标和高宽等信息, 完成目标检测。

本文针对流型图片的特点, 搭建了基于 YOLOv3 的流型识别算法, 进行了相关的训练实验。实验中采用重建流型图像和用 DCGAN 生成的流型图像作为数据集, 说明 DCGAN 扩增数据集的有效性, 并使用识别准确率这一指标来验证本文基于 YOLOv3 的流型识别算法在流型识别问题上的可行性。

用于分类的神经网络模型通常需要 3 部分数据集: 用于训练 (train) 的数据集、在训练过程中用于验证 (validation) 的数据集、以及对于训练好的模型测试 (test) 其识别准确率的数据集。最终的数据集构成如表 5 所示。

使用不同比例数据集对 YOLOv3 模型进行训练, 记录模型在验证集上的最终识别准确率, 并使用 5 次实验的平均值作为识别准确率的结果, 结果如图 6 所示。

表 5 不同比例实验数据集构成
Tab. 5 Experimental data sets of different proportions are constructed

数据集	数据集 1		数据集 2		数据集 3		数据集 4		数据集 5	
	重建 图像	生成 图像	重建 图像	生成 图像	重建 图像	生成 图像	重建 图像	生成 图像	重建 图像	生成 图像
测试集 Img_test	48	0	48	0	48	0	48	0	48	0
训练集 Img_train	134	0	134	1 260	134	2 940	134	4 200	0	4 200
验证集 Img_validation	58	0	58	540	58	1 260	58	1 800	0	1 800
流型识别数据集 Img	192	0	192	1 800	192	4 200	192	6 000	0	6 000

从图 6 可以看出, 随着数据集规模的增加, 模型的识别准确度随之上升。当使用全部的重建图

像和全部的扩增图像数据集进行训练时 (第 4 个实验), 模型的识别准确率最高, 达到 98. 67%。

当只使用 DCGAN 生成图像进行训练时(第 5 个实验),其识别准确度相较于全数据集(第 4 个实验)有一定下降。这说明,重构得到的原始图像和生成图像的分布仍具有部分区别,并不能将二者完全替换。因此可以得出,使用基于 YOLOv3 的流型识别算法在准确度上来讲是可行的,但是关于 DCGAN 生成的图像相当于对原始数据特征的丰富而非覆盖,恰当地运用扩增图像数据集可以大幅度提高模型的识别准确率。




图 6 使用不同比例数据集训练的 YOLOv3 的识别结果

Fig. 6 Recognition results of YOLOv3 trained with different scale datasets

用训练好的图像重建模型和训练好的基于 YOLOv3 的流型识别算法进行在线测试。图像重建和流型识别的实验环境使用如图 7 所示的气力输送实验测试平台,主要包括载气供气、送料、实验测量、节流装置这 4 个子系统。

实验中,流型实验选用平均直径为 $0.55\text{ }\mu\text{m}$ 的煤粉,送气风速设定为 24 m/s ,环境温度控制在 $19\sim 21\text{ }^{\circ}\text{C}$,相对湿度为 $45\%\sim 55\%$ 。

首先,将不同形状的节流阀固定在管道内部作为流型发生器,其可以控制流量参数并产生不同形状、不同尺寸的多种流型。本实验采用 4 种不同的节流阀以分别产生核心流、环状流、偏心

流、层状流 4 种流型。在每个流型测量实验开始之前,要进行测试实验,通过 1 个电磁阀多次将煤粉从无流量到短暂流量状态进行输送。与此同时,观察安装在节流装置后侧的网格状屏幕上的煤粉图像,直到得到实验所需的流型后,再将屏幕撤除进行测量实验。




图 7 气力输送实验平台^[3]

Fig. 7 Pneumatic conveying experiment platform^[3]

数据集选取 4 种流型共 48 组,每种流型 12 组数据进行实验。实验具体过程为:根据测量电容值进行图像重建;然后,将重建的图像利用训练好的基于 YOLOv3 的流型识别算法进行流型识别。识别过程满足每秒 2 次的工业过程控制速度要求。最终以测试流型和对应识别结果的形式给出,则 48 组数据的实验结果如表 6 所示。

一共 48 个流型图像,只有 1 个环形流被识别为偏心流,核心流、层状流、偏心流的识别率都达到 100%,则平均识别准确率达到 97.92%。本文提出的“从离线训练到在线识别”的流型识别技术对识别准确率有显著提高。利用已经离线训练好的模型进行在线流型识别,不再需要漫长的数据集扩增的部分,可以大大减少识别时间,因而能够满足工业控制的速度要求。

表 6 使用改进流型识别技术的测试结果

Tab. 6 Test results using improved flow pattern recognition techniques

测试流型	识别结果				
	核心流	层状流	环形流	偏心流	识别率/%
核心流	12	0	0	0	100.00
层状流	0	12	0	0	100.00
环形流	0	0	11	1	91.67
偏心流	0	0	0	12	100.00

5 结语

本文通过 DCGAN 进行流型图像数据集扩增,得到生成的流型图像每种流型 1 500 个,4 种流型共 6 000 个。相较于原有重建所得的 240 个图像,数据集得到了 25 倍扩增,并且对生成的图像进行客观评估,采用了 GAN-train 和 GAN-test 两个评价指标,从定量角度分析,采用此算法生成的数据集的准确度较高,且丰富性较强。之后利用扩增后的数据集进行 YOLOv3 模型的训练,并用训练好的模型进行在线流型识别测试。测试结果表明,本文搭建的 YOLOv3 模型在满足工业控制速度的要求下,识别准确率可以达到 97.92%。以上实验结果充分证明了基于 DCGAN 进行流型图像数据增强的有效性,得到的扩增数据集可以有效支持识别模型的训练。因此,本文提出的基于 DCGAN 的数据集增强方法以及基于 YOLOv3 的流型识别算法可以对 ECT 系统的流型识别准确率提升有较大幅度的改进。

参考文献

- [1] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6):84-90.
- [2] 刘起超,周云龙,陈聪. 基于 CEEMDAN 和概率神经网络的起伏振动气液两相流型识别[J]. 仪器仪表学报, 2021, 42(10):84-93.
LIU Q C, ZHOU Y L, CHEN C. Flow pattern identification of fluctuating vibration gas liquid two phase flow-based on CEEMDAN and probabilistic neural network [J]. Chinese Journal of Scientific Instrument, 2021, 42(10):84-93.
- [3] 王小鑫,王博,陈阳正,等. 基于电容层析成像技术重构图像的两相流型识别[J]. 计量学报, 2020, 41(8):942-946.
WANG X X, WANG B, CHEN Y Z, et al. Two-phase flow pattern recognition based on electrical capacitance tomography reconstructed images[J]. Acta Metrologica Sinica, 2020, 41(8):942-946.
- [4] 王莉莉,乔立勇,陈宇,等. 基于特征提取和 RBF 神经网络的 ECT 流型辨识[J]. 计算机工程与应用, 2011, 47(5):175-178.
WANG L L, QIAO L Y, CHEN Y, et al. Flow pattern identification based on feature extraction and RBF neural network for electrical capacitance tomography[J]. Computer Engineering and Applications, 2011, 47(5):175-178.
- [5] 宋蕾,陈德运,姚玉梅,等. Elman 神经网络在 ECT 系统流型辨识中的应用[J]. 哈尔滨理工大学学报, 2014, 19(5):103-108.
SONG L, CHEN D Y, YAO Y M, et al. Application of Elman neural network in pattern identification for electrical capacitance tomography[J]. Journal of Harbin University of Science and Technology, 2014, 19(5):103-108.
- [6] 张立峰,佟彤. 基于 GA-ELM 及电容层析成像的两相流型辨识[J]. 电力科学与工程, 2020, 36(8):37-41.
ZHANG L F, TONG T. Identification of two-phase flow based on genetic algorithm-extreme learning machine and electrical capacitance tomography [J]. Electric Power Science and Engineering, 2020, 36(8):37-41.
- [7] XIE Q Z, DAI Z H, HOVY E, et al. Unsupervised data augmentation for consistency training[C] // Proceedings of 34th International Conference on Neural Information Processing Systems. New York: ACM, 2020: 6256-6268.
- [8] NAZKI H, LEE J, YOON S, et al. Image-to-image translation with GAN for synthetic data augmentation in plant disease datasets [J]. Korean Institute of Smart Media Journal, 2019, 8(2):46-57.
- [9] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep convolutional generative adversarial networks [EB/OL]. (2016-01-07) [2022-10-20]. <https://arxiv.org/abs/1511.06434>.
- [10] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift [EB/OL]. (2015-03-02) [2022-10-20]. <https://arxiv.org/abs/1502.03167>.
- [11] ZHANG R. Making convolutional networks shift-invariant again [EB/OL]. (2019-06-09) [2022-10-20]. <https://arxiv.org/abs/1904.11486>.
- [12] RUDER S. An overview of gradient descent optimization algorithms [EB/OL]. (2017-06-15) [2022-10-20]. <https://arxiv.org/abs/1609.04747>.
- [13] DUCHI J C, HAZAN E, SINGER Y. Adaptive sub-gradient methods for online learning and stochastic optimization[J]. Journal of Machine Learning Research, 2011, 12:2121-2159.
- [14] KINGMA D P, BA J. Adam: A method for stochastic optimization [EB/OL]. (2017-01-30) [2022-10-20]. <https://arxiv.org/abs/1412.6980>.

- [15] WU Z X, HE S P. Improvement of the AlexNet networks for large-scale recognition applications[J]. Iranian Journal of Science and Technology, Transactions of Electrical Engineering, 2021, 45(2): 493-503.
- [16] 郑宗生, 刘贝, 卢鹏, 等. 基于 AlexNet 的近岸水生植物光谱分类及特征光谱分析[J]. 中国激光, 2023, 50(2): 129-138.
- ZHENG Z S, LIU B, LU P, et al. Spectral classification and characteristic spectral analysis of nearshore aquatic plants based on AlexNet[J]. Chinese Journal of Lasers, 2023, 50(2): 129-138.
- [17] 巩泉役, 彭克, 陈羽, 等. 基于电弧随机性和卷积网络的交流串联电弧故障识别方法[J]. 电力系统自动化, 2022, 46(24): 162-169.
- GONG Q Y, PENG K, CHEN Y, et al. Ac series arc fault identification method based on arc randomness and convolutional network[J]. Automation of Electric Power Systems, 2022, 46(24): 162-169.
- [18] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2015-04-10)[2022-10-20]. <https://arxiv.org/abs/1409.1556>.
- [19] 何其霖, 穆平安. VGG 网络与多特征融合的遮挡人脸检测[J]. 电子测量技术, 2021, 44(18): 150-154.
- HE Q L, MU P A. Occlusion face detection based on VGG network and multi-feature fusion[J]. Electronic Measurement Technology, 2021, 44(18): 150-154.
- [20] 孙继平, 范伟强. MS-ADoG 域结合 ReNLU 与 VGG-16 的矿井双波段图像融合算法[J]. 光子学报, 2022, 51(3): 1-15.
- SUN J P, FAN W Q. MS-ADoG domain combined with ReNLU and VGG-16 mine dual-band image fusion algorithm[J]. Acta Photonica Sinica, 2022, 51(3): 1-15.
- [21] REDMON J, FARHADI A. YOLOv3: An incremental-improvement[EB/OL]. (2018-04-08)[2022-04-06]. <https://arxiv.org/abs/1804.02767>.
- [22] 杨坤志, 闫潇宁, 孙健, 等. 一种雨雾背景的 DeRF-YOLOv3-X 目标检测方法[J]. 传感技术学报, 2022, 35(9): 1222-1229.
- YANG K Z, YAN X N, SUN J, et al. A DeRF-YOLOv3-X object detection method for rainy and foggy background[J]. Chinese Journal of Sensors and Actuators, 2022, 35(9): 1222-1229.
- [23] 王非, 王欣宇, 周景春, 等. 一种基于 YOLOv3 的水下声呐图像目标检测方法[J]. 电子与信息学报, 2022, 44(10): 3419-3426.
- WANG F, WANG X Y, ZHOU J C, et al. An underwater object detection method for sonar image based on YOLOv3 model[J]. Journal of Electronics & Information Technology, 2022, 44(10): 3419-3426.
- [24] 张官荣, 赵玉, 李波, 等. 基于 YOLOv3 的 SAR 舰船图像目标识别技术[J]. 电光与控制, 2022, 29(9): 107-110.
- ZHANG G R, ZHAO Y, LI B, et al. Ship target detection in SAR image based on YOLOv3[J]. Electronics Optics & Control, 2022, 29(9): 107-110.
- [25] 祖鑫萍, 李丹. 基于无人机图像和改进 YOLOv3-SPP 算法的森林火灾烟雾识别方法[J]. 林业工程学报, 2022, 7(5): 142-149.
- ZU X P, LI D. Research on forest fire smoke identification method based on UAV images and improved YOLOv3-SPP algorithm[J]. Journal of Forestry Engineering, 2022, 7(5): 142-149.

(编辑 李 静)