

DOI: 10.13382/j.jemi.2017.06.018

航拍绝缘子卷积神经网络检测及自爆识别研究

陈庆 闫斌 叶润 周小佳

(电子科技大学 自动化工程学院 成都 611731)

摘要:无人机巡检通过搭载的高清相机和图传设备可获取大量详实的巡检影像。绝缘子是输电线路中极其重要且用量庞大的部件,在图像视频中快速准确地检测出绝缘子可为无人机贴近铁塔和输电线路进行细节巡视的测距和避障飞行提供可靠的依据;同时绝缘子为故障多发元件严重威胁电网的安全,需充分利用计算机技术对其进行故障诊断。通过搭建卷积神经网络,在由5个卷积池化模块和2个全连接模块组成的经典架构的基础上,对网络进行改进,实现在复杂航拍背景中绝缘子检测。同时在训练的网络模型中抽取绝缘子的特征融入自组织特征映射网络中实现显著性检测,结合超像素分割和轮廓检测等图像处理方法对绝缘子进行数学建模,提出一种针对绝缘子自爆故障的识别算法,取代人工分析,降低由人为经验判断可能造成的误差。经测试,复杂航拍背景下的绝缘子检测精度达90%以上,自爆识别准确率达到85%以上,均满足工程需求,有效提升巡检的效率和智能化水平。

关键词:卷积神经网络;绝缘子;自爆;检测;识别

中图分类号: TP183 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Insulator detection and recognition of explosion fault based on convolutional neural networks

Chen Qing Yan Bin Ye Run Zhou Xiaojia

(College of Automation Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China)

Abstract: Unmanned aerial vehicles (UAVs) equipped with HD camera can obtain a large number of detailed inspection images of the insulators which are indispensable components in the transmission lines. A quick and accurate detection of the insulator can provide a reliable basis for distance measurement and obstacle avoidance for UAV when flying close to towers for details. Simultaneously, as a fault-prone component, the insulators seriously threaten the network security, thus computer technology is required for fault diagnosis. The detection of the insulator image with the complex aerial background is implemented by constructing a convolutional neural network (CNN), which has the classic architecture of five modules of convolution and pooling, two modules of fully connected layers. In this paper, a recognition algorithm for explosion fault based on saliency detection is proposed, which uses the trained network model to extract the features. Then we put the saliency maps into a SOM network and build the mathematical module via super pixel segmentation, contour detection, and other image processing methods. The test shows that the algorithm can reduce the errors caused by manual analysis. The test also demonstrates that the detection rate of the insulator can reach 90% and the recognition rate of explosion fault can reach 85% with complex background. They effectively improve the efficiency of inspection and make the inspection more intelligent.

Keywords: convolutional neural networks; insulator; explosion; detection; recognition

1 引言

我国电网规模庞大,高压和超高压输电线路快速发

展。四川电网以“大电网、大枢纽、大平台”为发展目标,已逐步成为连通华中、华东、华北、西北四大区域电网的重要枢纽。绝大部分输电走廊处于崇山峻岭,交通死区,通讯盲区,甚至无人区,导致巡视难度大、周期长,巡视结

果受巡视人员技能以及天气、地形等客观因素影响较大。定期或不定期的进行电力巡视和检修维护是保障输电线路安全运行的必然手段。

绝缘子是输电线路中极其重要且用量庞大的部件,起到电气绝缘及机械支撑作用;同时绝缘子终年暴露在野外,要遭受自然天气、自然灾害,机械负荷以及人为因素的损害,又是故障多发元件,其表面污秽、裂纹、破损等表面缺陷严重威胁电网的安全运行。据统计,500 kV 输电线路由于绝缘子故障引起的停运事故目前已成为电力系统故障中所占比例最高的。

无人机巡视是人工和智能巡视相结合的一种新型巡视模式,由于其低成本、易操控、易悬停、准确、安全、维护简单等特点,逐步开始进入实用化的阶段^[1-2]。利用无人机搭载高清相机和图传设备对杆塔和线路的某些细节进行巡视,比如绝缘子污秽、裂痕、塔材锈蚀等,可将电力巡视视频实时传输至地面站,获取大量详实的线路通道航拍视频和照片。国网四川省电力公司检修公司共管辖500 kV 及以上输电线路137条,长度11 902 km,充分利用小型多旋翼无人机开展单基塔的精细化检查、缺陷及隐患监测、专项特巡等生产工作,共计开展任务飞行133次496架次。2014年6月开始利用固定翼和多旋翼无人机对±800 kV 宾金线、复奉线、锦苏线三大特高压直流开展满负荷运行保电特巡,完成了三大直流通道巡检和重点杆塔精细化巡检513 km。经实测,仅±800 kV 宾金线巡检影像资料就达80 GB,日常拍摄一基杆塔的照片数超过50张250 MB。如何在海量的航拍视频和照片中快速准确地检测出绝缘子,是为无人机贴近铁塔和输电线路进行细节巡视的测距和避障飞行提供可靠的依据。同时,通过无人机搭载高清相机和图传设备,将电力巡视视频实时传输至地面站进行智能故障诊断,取代人工分析,将有效提升巡检的效率和智能化水平。

在国外,图像处理技术和机器视觉广泛应用于电力巡检中的识别和检测任务。文献[3]利用图像的分水岭算法来检测绝缘子表面的污秽;结合直方图的统计特性和基于奇异值分解定理的线性代数特征,已成功设计神经网络关联捕获的绝缘子图像并判断其污染水平^[4]。澳大利亚的Oberweger等人^[5]提出基于局部梯度描述符的方法自动提取单个绝缘子帽,然后使用描述符与椭圆空间支持来检测绝缘子并自动分析可能的故障。利用分割算法^[6]、轮廓提取算法^[7]、纹理特征提取^[8]等图像处理方式,计算机可提取航拍图像中的绝缘子进行检测和故障分析^[9-10]。国内,文献[10]结合绝缘子整串的形状特征描述子,利用阈值分割和边缘检测的方式可实现对绝缘子串快速定位。目前利用绝缘子颜色特征和形态学特征,利用阈值分割算法对其进行分割提取^[11-14]是常用的方法。同时结合形态学特征、遗传算法和BP神经网络等

方法,可实现绝缘子故障检测^[15-16]。

这些方法都是基于传统的模式识别的方式,特点是对待处理的图像进行预处理后,采用人工设计的特征来对目标进行描述,然后结合浅层机器学习的模型来进行分析和识别。本文采用近几年深度学习发展浪潮中的卷积神经网络模型实现对绝缘子的端到端的智能检测,使计算机快速识别出图像中的绝缘子,并准确得出绝缘子的位置,为无人机的避障和测距和绝缘子故障检测提供依据;并针对绝缘子自爆故障诊断进行算法设计,使得对绝缘子航拍图像进行检测达到智能化。

2 卷积神经网络的概述

2.1 卷积神经网络的发展

深度学习自2006年以来,在某种程度上可以说是引领了一场大数据时代下的科技革命。深度学习的产生和崛起并非一日成名,而是有着深厚的历史积淀。直观上,它是神经网络在大数据时代新的发展,然而从“浅”走到“深”却经历了很长的曲折与积累。卷积神经网络作为一种已经存在的,有一定应用经验的深度结构,重新回到人们视线,得益于大规模的数据、不断发展的硬件支持和优化技巧。目前,卷积神经网络已应用各个领域,如交通信号识别、语音识别、视频分类、面部探测、文本识别、行人检测、年龄估计,是近10年来人工智能领域取得的最重要的突破的利器。

卷积神经网络是深度学习模型的一类,早在20世纪60年代,Hubel和Wiesel在研究猫脑皮层中用于局部敏感和方向选择的神经元时发现其独特的网络结构可以有效地降低反馈神经网络的复杂性,继而提出了卷积神经网络。Fukushima在1983年提出的神经认知机是卷积神经网络的第一个实现。1988年Yann等人提出反向传播算法,极大地推动了卷积神经网络的发展。Yann等人于1998年提出LeNet-5网络结构,成功应用于语音识别和文档阅读。近几年,以物体检测和分类方面的主流数据库和国际视觉算法竞赛PASCAL VOC和ILSVRC竞赛的数据足以说明卷积神经网络应用之广泛^[17]。2012年,Hinton改进了卷积神经网络的训练方式,取代传统人工设计特征然后学习分类器的思路,并将其应用于ImageNet,取得了最好的分类效果,把错误率大幅降到15.315%,位居第2的传统计算机视觉方法在这个测试集上最低的错误率是26.172%。在ILSVRC 2014比赛中,获胜者GoogleNet将错误率再降到6.656%。

2.2 卷积神经网络的特点

卷积神经网络与普通的多层神经网络类似,它将图像处理中的二维离散卷积运算和人工神经网络相结合,

主要应用于二维图像的识别。卷积神经网络不仅关注了图像 RGB 三通道特征,还强调了空间二维坐标,因此其擅长处理二维图像数据,避免了对图像的复杂前期预处理,可以直接输入原始图像进行处理,因而得到了更为广泛的应用。

2.2.1 卷积

图像是 5 维信息,单纯的神经网络把图像拉伸为向量反而丢弃了空间信息。而卷积神经网络通过卷积核以兴趣点为中心的一小块区域,探测上一层特征的局部连接,对其进行过滤和特征强化,更符合图像的二维空间的本质,因而可以学习更有效的特征。

2.2.2 池化

池化可以简单理解为降采样操作,它是一个非参数层。它将一定领域内的像素压缩成一个像素点,学习图像的空域特征,把相似的特征合并起来,使得图像逐层缩放,降低卷积层的复杂度,抑制过拟合现象。池化一般配合卷积层使用,可以获得特征的不变性,提升对微小畸变和旋转的容忍能力,增强模型泛化能力。常见的操作有锐化、平滑和随机池化 3 种。

2.3 卷积神经网络的技术

2.3.1 局部连接

对于图像数据而言,一个像素值的附近的值是高度相关的,距离较远的像素相关性较弱,可以形成比较容易探测到的有区分性的局部特征。因此,取代传统的全连接或稠密连接方式,卷积神经网络采用局部连接,对局部进行感知,而在高层将局部信息综合。局部连接显著减少每层神经元的参数个数,使得误差以较小的广度发散,更符合人的视觉局部感受野的概念。

2.3.2 权值共享

同时,图像中不同位置的局部统计特征不太相关,在一个局部位置出现的特征,也可能出现在另一个位置。可见卷积的提取操作与位置无关,不同位置的单元可以共享权值进行特征学习,同时设计不同的卷积核探测不同的特征。

2.3.3 激活函数

激活函数一般用于卷积层和全连接层之后,激活函数是深度网络非线性的主要来源。常见的激活函数 Sigmoid、tanh、ReLU、PReLU、ELU 和 maxout。其中 PReLU 和 ELU 都是 ReLU 的改进。

早期的 Sigmoid 函数容易饱和,造成梯度终止传递,并且没有 0 中心化。同时标准的 Sigmoid 输出不具备稀疏性,需要用一些惩罚因子来训练出一大堆接近 0 的冗余数据,从而产生稀疏数据,因此需要进行无监督的预训练,否则将导致网络无法收敛。ReLU^[18] 是修正线性函数,来源于生物神经元,同时具备相对对称性与不对称性,不会出现梯度消失的问题。而且求梯度简单,收敛

快,精确度高,具备引导适度稀疏的能力。

2.3.4 Dropout

为了防止过拟合,可采用产生更多的训练数据的方式,比如将已有的训练数据进行翻转,或根据主成分分析改变 RGB 通道的值。另一种避免深度网络过拟合的随机正则化策略为弃权 Dropout^[19],由 Hinton 于 2012 年提出,Dropout 随机将隐层中比例为 p 的神经元输出设置为 0,引入随机化的稀疏性,让庞大的网络在同一时刻只工作一部分,加快训练速度。正则化的测试使得参数不停地受到惩罚,被迫向稳定的方向调整,使训练结果更稳定,提高泛化能力。相继又出现了 Dropconnect 等技术。

2.3.5 Normalization

为使数据分布一致增加网络泛化能力,需要对数据进行归一化处理。通常采取方法有 Min-Max Normalization 离差标准化,对原始数据的线性变换,使结果值映射到 $[0, 1]$; Z-score 标准化方法给予原始数据的均值和标准差进行数据的标准化,经过处理的数据符合标准正态分布。而深度网络中归一化技术也在不断改进,如 LRN、LCN 和 Batch Normalization。若每批数据的分布各不相同,网络需要学习以适应其不同的分布,速度将大大降低。Batch Normalization^[20] 提出于 2015 年,通过逐层尺度归一,解决数据分布发生改变的问题,避免了梯度消失和梯度溢出。同时可以加速收敛,作为一种正则化技术提高了泛化能力。

2.3.6 训练方法

BP 算法于 1974 年提出,在 1986 年引发广大关注得以广泛使用,分为链式求导和梯度反向传播两个部分。卷积神经网络的训练方式和 BP 类似,在反向传播时一般采用梯度下降 (gradient descent)。在训练数据单次迭代的样本数量上,分为针对整个训练集的 GD 或者针对单个样本的 SGD。前者算法复杂度高时效性低,后者算法复杂度低但是收敛不稳定。因此出现了介于两者中间的 Mini-Batch SGD,其单次迭代的样本为训练集的随机组合的子集。其中有两个技术细节,权值衰减 (weight decay) 作为一种正则化的手段可避免过拟合,冲量 (momentum) 可避免陷入局部最优。

早期的损失函数一般选择最小化平方误差 (MSE) 或者最小化相对熵 (relative entropy),随着不断的发展,出现了用于单标签分类的 softmax 损失函数,用于实值回归问题的 Euclidean 损失函数,用于多标签分类的 Sigmoid 交叉熵损失函数和用于深度测度学习的 Contrastive 损失函数等等。

卷积神经网络最核心的地方在于卷积和池化操作。利用权值共享和局部链接等空间关系等技术减少网络参数,降低模型的复杂度。卷积神经网络应用在图像领域

更加有效,因为其不但关注了全局特征,更是利用了图像识别领域非常重要的局部特征,集成了对全局和局部特征的综合把握。一个模式识别系统包括特征和分类器两个主要的组成部分,二者关系密切,而在传统的方法中它们的优化是分开的。在卷积神经网络的框架下,特征表示和分类器是联合优化的,可以最大程度发挥二者联合协作的性能,使得端到端的系统成为可能。

3 卷积神经网络实现绝缘子检测

针对航拍图像多角度多尺度和背景复杂等特点,绝缘子的提取和定位至关重要。在识别与检测任务中,设计良好的特征是识别成功的关键。由于特征具有多样性,采用手工选取特征费时费力,需要启发式专业知识和经验甚至运气。当然也有一些良好的特征如 SIFT、HoG、LBP 等为大众所知,但应用到实际工程中仍需针对特定的场景精心设计。深度卷积神经网络避免了显式地手工设计特征,而隐式地从大数据中自动学习特征。通过构建深层模型和海量的训练数据,学习更有用的特征,从而最终提升分类或预测的准确性。

3.1 Cellular Automata 显著性检测

卷积神经网络最后使用全连接网络得到固定长度的特征向量表征概率进行分类。与物体分类要建立图像理解任务不同,有些应用场景下要得到图像像素级别的分类结果,以语义图像分割为例,其目的是将图像分割为若干个区域,使得语义相同的像素被分割在同一区域内。显著性检测也是一种像素级的分割,可筛选出感兴趣的目标和区域,具有一定的主观性。显著性检测能够把有限的处理资源快速而准确地分配到显著的视觉区域上,突出了图像中的显著目标,削弱了目标周围场景对于目标的影响。传统的图像显著性检测采用自底向上的方法,从区域纹理、颜色、对比度、HOG、SIFT 等大量中低层特征出发,通过逐层特征抽取,实现显著与非显著性的区分。

显著性检测方法 SLIC^[21] 使用广泛。文献[22] Cellular Automata 在 SLIC 的基础上对其进行了提升。本文采用 Cellular Automata 进行图像显著性检测,将得到显著图输入卷积神经网络之中。通过基于显著性的绝缘子候选区域提取,排除超过 50% 的待判区域。得到显著图已排除了大量背景的干扰,大幅度减少搜索的范围,提升后续 object proposal 的处理速度。同时利用显著图,为后面的绝缘子自爆识别奠定基础。

图 1 所示为原始图像和 Cellular Automata 显著性检测得到的绝缘子图像。可见对于目标突出且背景简单的图像,显著性检测效果良好,对于复杂背景,目标不够突出,包含了部分背景像素,需对其进行优化。




图 1 Cellular Automata 显著性检测效果

Fig. 1 Cellular Automata saliency detection result

3.2 卷积神经网络的模型结构

卷积神经网络一般由卷积层,池化层和全连接层组成,其经典结构在于由卷积层和池化层逐交替,最后连接全连接层得到预测输出。通常 CNN 网络在卷积层之后会接上若干个全连接层,将卷积层产生的特征图映射成一个固定长度的特征向量,得到整个输入图像的一个数值描述以表示输入图像属于每一类的概率。从不断发展的卷积神经网络模型,如早期 Yann 等人提出的 LeNet, 2012 年 ILSVRC 比赛远超第 2 名的卷积神经网络 AlexNet^[23], 2013 年的冠军网络 ZF^[24], 2014 年 ILSVRC 比赛中冠亚军的 GoogLeNet^[25] 和 VGGNet^[26], 这些经典模型的深度逐年加深,识别效果越来越好。

检测通常采取区域选择,特征设计和分类器判别的构架,如 RCNN^[27]。从传统的滑动窗口到 selective search^[28] 和 edge boxes^[29] 等 object proposal 技术,使得检测的速度和精度大大提升。本文采用 fast-rcnn^[30] 的模式,用 edge boxes 产生 object proposal 送入卷积神经网络之中,然后使用分类器进行识别,窗口回归进行定位。模型参数远大于或者小于数据量时容易形成过拟合和欠拟合的问题,应当尽可能使模型参数与数据量匹配,并结合调参的技术。越大的模型参数越多越难训练。考虑到本文特定的识别对象为输电线路中具有特征明显的绝缘子及训练数据的复杂度、工程实时性和硬件的需求,采用经典的 5 个卷积层和 2 个全连接层搭建的网络模型及参数如图 2 所示。

结合近年来网络模型调参的最新技术,本文网络的详细信息如下:

- 1) 将卷积核的大小进行缩小,采用 7×7 , 5×5 和 3×3 的卷积核进行卷积以获取更详细的局部信息;
- 2) 采用 BP 训练方法,反向传播时使用 SGD 方式进行训练;
- 3) 损失函数采用单标签分类的 Softmax 函数;
- 4) 在每一层的 ReLU 前进行 Batch Normalization;
- 5) 分类器采用二分类的支持向量机(SVM),对比 Boosted Trees、Random Forest、Decision Tree、Logistic Regression 和 Softmax Regression, SVM 效果最好。

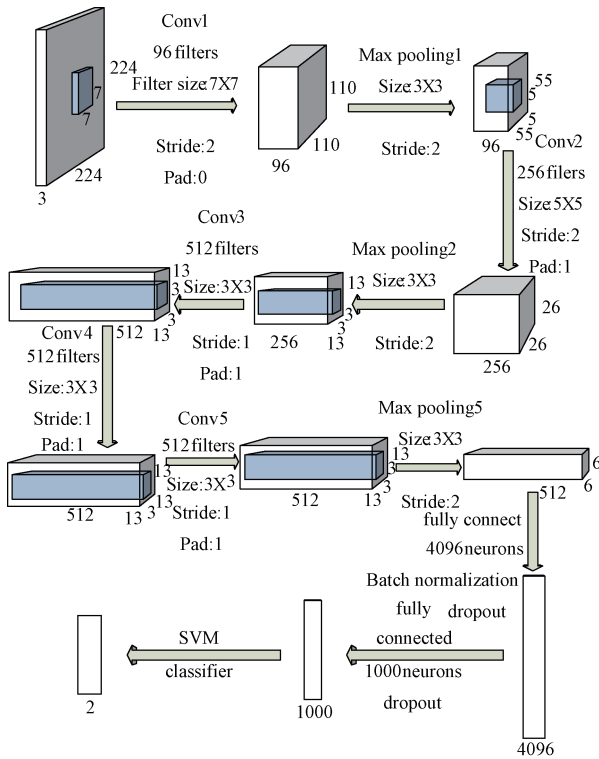


图 2 卷积神经网络的参数模型

Fig. 2 Parameters model of convolutional neural networks

迭代 4 万次,最终网络收敛。本文搭建的网络模型如图 3 所示。

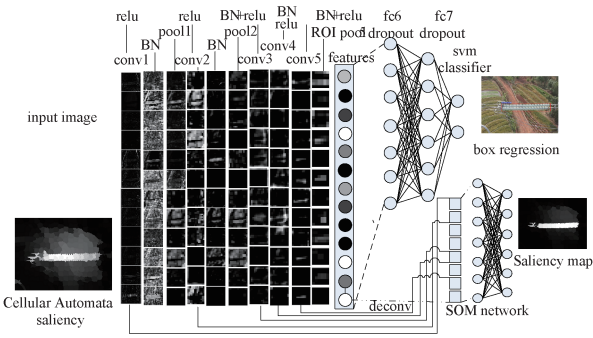


图 3 网络整体构架


Fig. 3 Overall architecture of network

将训练好的网络作为特征抽取工具,把逐层处理得到的绝缘子特征图随机采样并进行反卷积操作得到归一化的尺寸,作为自组织特征映射网络的输入样本。对该 SOM 网络进行训练,得到生成显著图的网络。


3.3 逐层特征可视化

由于目标的形态多样性、光照变化多样性、背景多样性等因素使得设计一个鲁棒的特征并不是那么容易。卷积神经网络通过层级结构,可以自动从海量的数据中学习具有表征性的特征。卷积神经网络和普通的神经网络一样,由神经元按层级结构组成,其间的权重和偏移量都


是可训练得到的。将航拍绝缘子图片输入训练好的卷积神经网络模型,分析经过卷积层和池化层处理后的特征图,有助于理解特征的层级组合。图 4 所示为输入层




(a) 输入层图像
(a) Input Image



(b) Conv1 层
(b) Conv1 layer



(c) Pool1 层
(c) Pool1 layer



(d) Conv5 层
(d) Conv5 layer



(e) Pool5 层
(e) Pool5 layer

图 4 特征可视化

Fig. 4 Feature visualization

(input), 底层(conv1 和 pool1) 和高层(conv5 和 pool5) 的绝缘子特征图。

可见, 随着网络层次的递增, 特征越来越抽象。低层特征经过组合与重构, 形成更具表达能力和稀疏的高层特征, 综合全局与局部的把握。

如图5所示, 针对同一时间段, 同一巡视场景, 无人机在不同光照, 多尺度和多角度拍摄情况下, 对航拍铁塔上的同一串绝缘子检测效果优良。




图5 绝缘子检测效果

Fig.5 Detection result of insulator

4 绝缘子自爆识别的实现

利用旋翼无人机良好机动性和操控性, 依靠搭载的高分辨率遥控相机从多角度近距离拍摄目标图像, 获取不同类别的缺陷的关键细节。这些多角度的关键细节是人工巡视无法获取的。通过高清数字图传设备将拍摄的影像传输至地面监控站可供工作人员进行细节查看。但是采用人工方式判断巡检视频是否存在绝缘子隐患或故障, 效率底下且可能造成人为偏差。因此有必要在地面监控站开发绝缘子故障诊断系统, 智能判断故障, 提升巡检智能化水平。

由于季节更替, 天气变幻, 四川地区地形气候复杂, 导致航拍背景复杂多变。加上无人机航拍角度多变及尺度多变的影响, 使得许多传统基于浅层学习的算法的鲁棒性不高, 工程应用受限。同时, 绝缘子自爆图像样本相对正常样本数量而言, 样本量太小, 不满足深度卷积神经网络对训练数据量的要求, 因此需设计针对绝缘子自爆识别的算法。

4.1 结合 CNN 和 SOM 实现显著性检测

深度结构是手段, 特征提取是目的, 因此可以利用深度卷积神经网络对绝缘子的特征提取和识别能力, 成功地从复杂的航拍背景中智能地分割出待检测的目标。相比传统的基于图像的形态学, 颜色空间转换提取, 阈值分割等方式更直接有效。用于自爆检测的图像均为尺度调整后的图像, 绝缘子串上每个绝缘子清晰可见并像素足够多。

由3.1节利用 Cellular Automata 得到的显著图可知, 对于简单背景显著性检测效果优良, 对于复杂背景显著性检测仍包含其他信息, 需要进一步优化结果。目

前利用卷积神经网络, 条件随机场, 超像素实现显著性检测^[31-33]的方式也颇多。本文竞争网络采取 Kohonen 提出的自组织特征映射网络, 简称 SOM 网。典型 SOM 网共有两层, 分为输入层和竞争层, 输入层为样本的特征表达, 竞争层为输出层。本文采用余弦相似度作为相似性测量, 学习步骤描述如下。

1) 初始化: 对竞争层的权值进行初始化基本原则是尽量使权值的初始位置与输入样本的大概分布区域充分重合, 因此采用 Cellular Automata 得到的显著图对自组织特征映射的竞争层网络进行权值初始化, 再进行归一化得到 $w_j, j = 1, 2, \dots, m$ 。建立初始优胜领域 $N_j^*(0)$; 学习率 $\eta, \eta \in (0, 1)$ 进行初始化; 随机选取各个卷积层对训练样本处理得到的特征图若干, 进行反卷积操作得到统一的尺寸, 并进行归一化处理, 得到 $X_p, j = 1, 2, \dots, P$, 总共有 P 个数据。

2) 寻找获胜的神经元: 如式(2), 从 X_p 与所有 w_j 的内积中找到最大的 j^* 即竞争中获胜的神经元。

$$W_{j^*}^T \cdot X = \max_{i=1,2,\dots,P} (W_i^T X) \quad (2)$$

3) 定义优胜邻域 $N_{j^*}(t)$: 以 j^* 为中心确定 t 时刻的权值调整域, 如式(3)所示。

$$N_{j^*}(t) = C_1(1 - t/T) \quad (3)$$

随训练时间增长, 该领域逐渐收缩, C_1 是与输出层节点数有关的正常数, T 为预先选定的最大训练次数。

4) 调整权重: 对优胜邻域 $N_{j^*}(t)$ 内的所有神经元调整权重, 如式4所示。

$$w_{ij}(t+1) = w_{ij}(t) + \eta(t, N) [x_i^p - w_{ij}(t)] \quad (4)$$

式中: $\eta(t, N)$ 是训练时间 t 和邻域内第 j 个神经元与获胜神经元 j^* 之间的拓扑距离 N 的函数, 随着时间增加, 拓扑距离的增大, 学习率降低。

通过不断地将所有样本数据输入网络进行训练, 最终权值将会趋于稳定, 学习率 η 小于设定阈值, 即可得到用作显著性检测的 SOM 网络。

4.2 建立绝缘子串的数学模型

结合 CNN, 将卷积层处理得到的特征图经反卷积处理后得到统一的尺寸, 输入 SOM 网络, 进行显著性检测。绝缘子区域内对应节点的值输出最大, 得到更新后的显著图。其滤除的背景和保留的绝缘子将更加精确和清晰。然后本文算法利用超像素^[34]算法将图像细分为多个图像子区域, 通过对图像中的每个像素加标签使得具有相同标签的像素具有某种共同视觉特性, 实现对单个绝缘子像素的聚合, 目的是为了得到单个绝缘子的轮廓。

得到单个绝缘子的轮廓后, 可建立绝缘子串的数学模型。通过求取轮廓的外接矩形求取单个绝缘子的区域坐标 $P(x, y)$ 及其宽度 width 和高度 height, 及绝缘子的

个数 N 。对分割出的绝缘子进行轮廓检测,并获得绝缘子的中心。通过对单个绝缘子中心进行最小二乘法直线拟合,得到绝缘子串骨干线 $y = kx + b$,计算出与 x 轴的角度 θ 。利用单个绝缘子区域坐标 $P(x, y)$ 和绝缘子串的中心线 $y = kx + b$,建立绝缘子的数学模型如图 6 所示。




图 6 绝缘子串数学模型

Fig. 6 Mathematical model of insulator

每个绝缘子都带有金具,且尺寸规格相同,在轮廓分割的条件下,绝缘子的区域大小相差不大,区域的面积 $area$ 定义为 $area = width \cdot height$ 。若存在绝缘子自爆故障,则在骨干线上只保留了金具,缺失了盘形绝缘子的玻璃叶片,该区域的面积 $area$ 将比其他区域面积偏小。经多次计量,可得到存在绝缘子自爆故障的面积阈值 $threshold_area$ 。

同时,对每个绝缘子区域进行有效像素比例的统计,即获取高亮度值的像素个数 $count_i$ 。经反复实际测试,得到有效像素比例的阈值 $threshold_count$ 。针对绝缘子自爆故障检测软件的算法如图 7 所示。

4.3 绝缘子自爆缺陷识别

本文采用的绝缘子自爆特征定位方式是通过先统计标定区域内白色像素点的面积比例和区域面积,再与预先设定的比例阈值进行比较,判断是否存在自爆,判断条

$$\begin{cases} |rate_i = \frac{count(i)}{areai} - average_rate| < threshold_rate \& areai < average_area, & \text{自爆} \\ \text{其他,} & \text{无自爆} \end{cases} \quad (5)$$

$$average_rate = \frac{1}{N} \sum_{i=1}^N rate_i$$

$$average_area = \frac{1}{N} \sum_{i=1}^N area_i \quad (6)$$

式中: $areai$ 代表每个绝缘子的区域面积, $count_i$ 为绝缘子的有效像素和, $rate_i$ 代表以第 i 个绝缘子的像素总和与为该绝缘子区域面积有效像素的比例, $width$ 和 $height$ 分别为获取的绝缘子区域的宽和长, N 为该串绝缘子串上获得的区域中心点的总个数。

经反复测试, $threshold_rate$ 取 0.25 时说明改位置像素偏少,即反应出该位置绝缘子存在自爆。并标记该位置,进行输出。该算法简单快捷,不需要经过图像处理的方法,直接在提取出的绝缘子图像上即可实施。

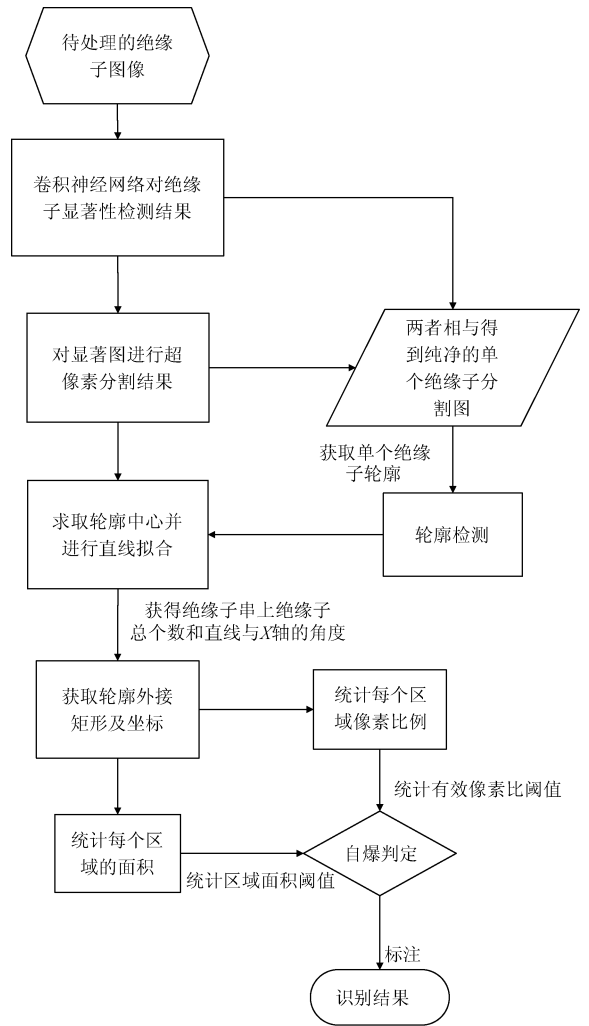


图 7 绝缘子自爆缺陷图像识别算法

Fig. 7 Image recognition algorithm of insulator explosion fault

件如式(5)所示,设定的阈值如式(6)所示。

5 测试与验证

5.1 绝缘子检测测试

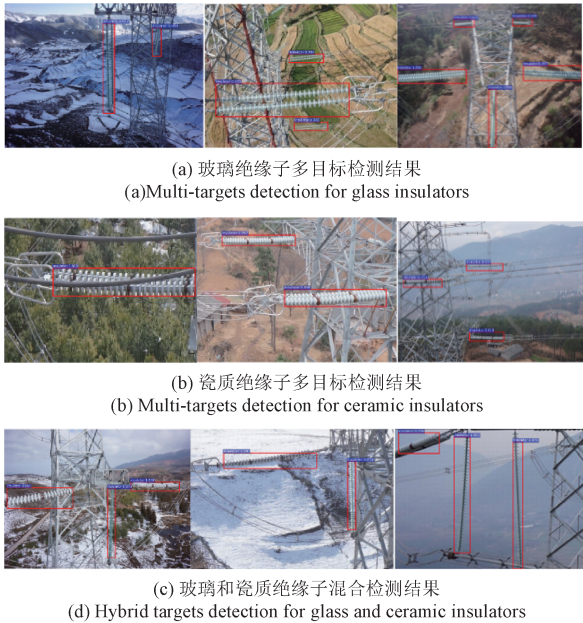
测试的平台为 Linux 系统, Intel 酷睿 2 双核, CPU 2.67 GHz, 内存 DDR3 1 333 Hz 容量 8 G, GPU 显存 3 G。计算机视觉库采用 openCV2.4.9。深度学习框架采用清晰高效的 Caffe^[35], 它是纯粹的 C++/CUDA 架构, 支持命令行, Python 和 MATLAB 接口。

四川省地势西高东低, 境内高原、山地、丘陵地形占全省土地面积比例为 97.46%, 除此之外, 多数地区的岭谷高差均都在 500 m 以上。四川地区铁塔多为猫头塔、羊角塔、干字型塔和酒杯塔, 绝缘子多为盘形悬式瓷质绝

缘子和盘形钢化玻璃绝缘子,绝缘子串多为悬垂式分布和耐张式分布,且通常采用两串绝缘子并联悬挂方式。

利用无人机,在不同的季节,对不同的输电线路上的绝缘子采集样本。训练样本为 4 000 张绝缘子航拍图像,其中玻璃绝缘子图像 2 000 张,瓷质绝缘子图像 2 000 张。针对待检测的盘形悬式瓷质和盘形悬式玻璃绝缘子,利用卷积神经网络对其进行训练。为减轻标注的工作量,选取的每一张训练样本仅包含一对绝缘子串,分别呈现水平,竖直分别和多角度分布。

测试样本为 600 张航拍绝缘子图像。其中 200 张玻璃绝缘子图像,200 张瓷质绝缘子图像,200 张玻璃绝缘子和瓷质绝缘子混合的图像。测试效果如图 8 所示,效果优良。



(a) 玻璃绝缘子多目标检测结果

(a) Multi-targets detection for glass insulators

(b) 瓷质绝缘子多目标检测结果

(b) Multi-targets detection for ceramic insulators

(c) 玻璃和瓷质绝缘子混合检测结果

(d) Hybrid targets detection for glass and ceramic insulators

图 8 绝缘子测试效果

Fig. 8 Test results of insulator

测试结果表明,针对单一的玻璃绝缘子或者瓷质绝缘子,亦或是二者混合的情况,都表现出对多角度绝缘子的良好检测效果。目前识别和检测任务大量依赖人工设计特征,也出现了一些良好的特征如 Haar、SIFT、HoG、LBP 等。传统的识别检测方式针对不同的识别对象,需设计不同的特征和分类算法,比如针对人脸检测的经典算法采用 Haar 特征和 Adaboosting 分类器;针对行人检测的经典算法采用 HoG 特征和 SVM 分类器;针对一般的物体检测采用 HoG 特征和 DPM^[36] 算法。本文将卷积神经网络检测方式与采用传统的 HoG 特征和 SVM 方式及 DPM 方式做对比。针对同一训练集合,利用深度卷积神经网络和传统方式的检测效果对比如图 9 所示。

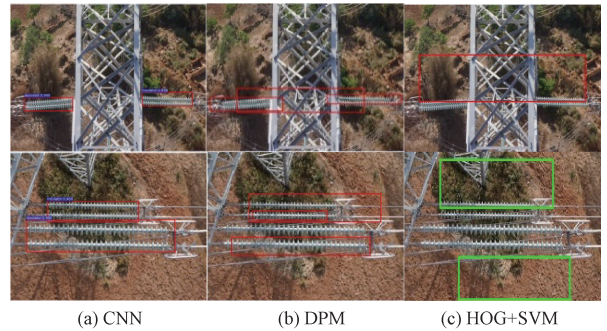


图 9 绝缘子检测效果对比

Fig. 9 Comparison of insulator detection results

通过对比试验,发现 DPM 和 HOG 存在误检,同时定位精度上不如卷积神经网络。

测试 500 张背景包含雪地,丘陵,草地,铁塔和房屋等复杂背景的航拍图像,采用 Navneet Dalal 的 HOG 特征加 SVM 的方式^[37],DPM 方式和卷积神经网络的方式的对比结果如表 1 所示。

表 1 绝缘子检测测试对比结果

Table 1 Comparison result of insulator detection

方式	漏检率/ %	误检率/ %	定位 精度	平均检测时间/ (ms/帧)
HOG + SVM	21.8	13.9	差	2 400
DPM	15.6	8.4	良好	1 600
CNN	5.1	2.3	优良	800

绝缘子的成功检测可作为无人机进行细节巡视时的标志,利用相机成像的原理,实时测出无人机相对于铁塔的相距,避免无人机误撞的危险,为无人机的避障飞行提供可靠的依据,灵活完成巡检任务。

5.2 绝缘子自爆识别测试

通过无人机搭载高清摄像机取得绝缘子航拍图像对其进行绝缘子目标检测后,提取较大尺度的绝缘子感兴趣区域进行自爆识别。经测试,本文绝缘子自爆图像识别算法对绝缘子的分割识别达到良好的效果。如图 10(a) ~ (f) 所示,分别展示了本文针对感兴趣绝缘子区域进行绝缘子显著图提取,求取逐个绝缘子轮廓,获得绝缘子区域坐标和自爆识别的重要环节示意图。

针对图 10 的绝缘子串的航拍图像,绝缘子区域面积的平均值为 4 267.16,第 13 个绝缘子的区域面积明显小于该面积,同时绝缘子有效像素比的平均值为 0.586 512,第 13 个绝缘子的有效像素比 *rate* 为 0.913 824,与平均值的差大于设定的阈值 *rate_threshold* 即 0.25,则判定第 13 个绝缘子位置为存在自爆。绝缘子自爆定位的结果如图 11 所示。

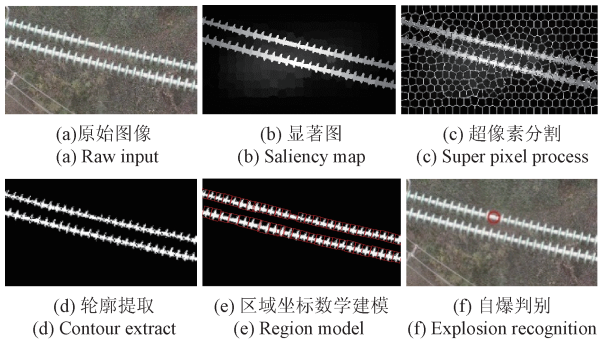


图 10 绝缘子自爆识别过程

Fig. 10 Schematic diagram of insulator explosion recognition process

Insulator No.1, region area is: 2565.83; effective proportion is: 0.522976
Insulator No.2, region area is: 4593.15; effective proportion is: 0.674552
Insulator No.3, region area is: 4962.71; effective proportion is: 0.682143
Insulator No.4, region area is: 4223.58; effective proportion is: 0.699163
Insulator No.5, region area is: 4638.74; effective proportion is: 0.581169
Insulator No.6, region area is: 4434.76; effective proportion is: 0.647811
Insulator No.7, region area is: 5173.89; effective proportion is: 0.647871
Insulator No.8, region area is: 5173.89; effective proportion is: 0.60348
Insulator No.9, region area is: 4329.17; effective proportion is: 0.632231
Insulator No.10, region area is: 4434.76; effective proportion is: 0.539767
Insulator No.11, region area is: 4487.56; effective proportion is: 0.637521
Insulator No.12, region area is: 4487.56; effective proportion is: 0.442243
Insulator No.13, region area is: 2187.35; effective proportion is: 0.913824
Insulator No.14, region area is: 4276.38; effective proportion is: 0.572428
Insulator No.15, region area is: 4593.15; effective proportion is: 0.588989
Insulator No.16, region area is: 4276.38; effective proportion is: 0.546587
Insulator No.17, region area is: 4884.33; effective proportion is: 0.541837
Insulator No.18, region area is: 5015.51; effective proportion is: 0.535167
Insulator No.19, region area is: 4329.17; effective proportion is: 0.498955
Insulator No.20, region area is: 4593.15; effective proportion is: 0.542757
Insulator No.21, region area is: 5068.3; effective proportion is: 0.488815
Insulator No.22, region area is: 4884.33; effective proportion is: 0.549657
Insulator No.23, region area is: 4434.76; effective proportion is: 0.493385
Insulator No.24, region area is: 4329.17; effective proportion is: 0.569438
Insulator No.25, region area is: 4989.92; effective proportion is: 0.555868
The average area of insulators : average_area = 4267.16
The average effective pixel proportion : average_rate = 0.586512
There are 25 insulators in total; the explosion defect appears in the No.13

图 11 绝缘子自爆识别

Fig. 11 Recognition of insulator explosion

绝缘子自爆图像识别算法测试采用 200 张航拍绝缘子图像,其中 100 张为简单背景下的绝缘子航拍图像,另外 100 张为复杂背景下的绝缘子航拍图像。每 100 张测试图片照片中,含有缺陷和无缺陷的样本各 50 张。测试过程中,用存在缺陷的样本来测试识别率与漏识率,用不存在缺陷的图像测试误识率。测试表明,本算法达到良好的识别准确率。在简单背景下,采用绝缘子颜色特征或者边缘形状特征等传统识别算法的准确率与本算法识别准确率均可达到 80% 以上,而在复杂背景下,由于卷积神经网络强大的特征学习能力,显著图快速排除复杂背景,准确地分割出待识别的绝缘子目标,识别准确率仍达到 80% 以上,与传统的人工设计绝缘子特征进行绝缘子分割的方法相比,识别效果表现出其优势。但对部分受拍摄角度影响的图像,导致自爆区域被掩盖,仍存在漏检情况,自爆试验结果如表 2 所示。

传统的人工巡视模式由于人员业务素质、地域跨度、地形结构、气象条件等的影响,巡视效率较低,时效性差,巡视不充分,缺陷发现不及时,线路隐患排除不充分。无

表 2 自爆检测实验结果

Table 2 Experimental test results of insulator explosion (%)

测试分类	缺陷图像的识别率	无缺陷图像误识率
简单背景	89.7	5.8
复杂背景	82.5	11.2

人机巡检可获得详实的细节图像,通过绝缘子自爆识别算法可有效减少人工干预,提升巡检效率和质量,保证输电线路安全运行。

6 结 论

四川地形复杂,气候多变,丘陵山壑、峡谷雪山密布,时有雨雪、洪涝、滑坡等自然灾害,输电线路穿越崇山峻岭,分散性大、距离长、难以现场巡视。无人机将人工巡视的“视线”延伸到野外山脊上的输电线路现场,多角度的巡视输电走廊、线路、塔身、塔基等相关巡视作业目标。

图像中的目标可能出现在任何位置,目标的形态可能存在各种各样的变化,图像的背景千差万别,这些都将导致目标检测并非一个简单的任务。

目前巡检影像分析由人工进行,超大的视频、图像给后期分析处理带来了巨大的工作量,对及时掌握线路运行情况极为不利。若对这些海量视频数据采用工作人员肉眼判读而没有自动图像分析功能的话,易发生严重的检测误判或漏判情况,难以准确发现绝缘子存在的安全隐患,且极大地增加了检修成本。因此利用图像处理技术研究绝缘子缺陷的自动检测方法是非常必要的。测试表明,利用卷积神经网络提取目标绝缘子的图像,通过设计针对绝缘子自爆的判别算法,提高检测的准确性,并在一定程度上避免了人工巡视和缺陷分析的不足,实现电力系统智能化。

下一步研究工作如下:

1) 针对已检测出的绝缘子,结合跟踪算法,实现对绝缘子的多角度多尺度跟踪,并实时测出无人机相对于绝缘子的距离,为无人机贴近铁塔进行细节巡视的避障飞行控制提供参考依据,使空中飞行平台巡线系统更为高效和智能。

2) 在绝缘子自爆识别的基础上,提升算法的自适应能力。本文自爆识别算法依赖于经验值,同时针对航拍角度存在遮挡问题,导致自爆区域被掩盖,需设计实用性更广鲁棒性更高的算法,提升巡视的自动化程度和巡视效率。

3) 研究更多类型的典型输电线路故障识别算法,如绝缘子污秽,导线覆冰和导线断股等。

参考文献

[1] TOTH J, GILPIN J A. Smart view for a smart grid-

- unmanned aerial vehicles for transmission lines[C]. 1st International Conference on Applied Robotics for the Power Industry (CARPI), IEEE, 2010: 1-6.
- [2] CAO W, ZHU L, HAN J, et al. High voltage transmission line detection for uav based routing inspection[C]. IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM), 2013: 554-558.
- [3] MEI X, LU T, WU X, et al. Insulator surface dirt image detection technology based on improved watershed algorithm[C]. Power and Energy Engineering Conference (APPEEC), 2012: 1-5.
- [4] MARAABA L, AL-HAMOUZ Z, AL-DUWAISH H. Estimation of high voltage insulator contamination using a combined image processing and artificial neural networks[C]. Power Engineering and Optimization Conference, 2014: 214-219.
- [5] OBERWEGER M, WENDEL A, BISCHOF H. Visual recognition and fault detection for power line insulators[C]. 19th Computer Vision Winter Workshop, 2014.
- [6] AYALA H V H, SANTOS F M D, MARIANI V C, et al. Image thresholding segmentation based on a novel beta differential evolution approach[J]. Expert Systems with Applications, 2014, 42(4): 2136-2142.
- [7] FANG T, JIN X, HU X L, et al. A fast insulator-contour-detection-algorithm on power transmission lines images[C]. Applied Mechanics & Materials, 2012, 201-202: 337-343.
- [8] LI W G, YE G SH, FENG H, et al. Recognition of insulator based on developed MPEG-7 texture feature[J]. High Voltage Apparatus, 2010 (1): 265-268.
- [9] MEI X, LU T CH, WU X Y, et al. Insulator surface dirt image detection technology based on improved watershed algorithm[C]. Proceedings of PEEC, 2012: 1-5.
- [10] 赵振兵, 王乐. 一种航拍绝缘子串图像自动定位方法[J]. 仪器仪表学报, 2014, 35(3): 558-565.
ZHAO ZH B, WANG L. Aerial insulator string image automatic location method [J]. Chinese Journal of Scientific Instrument, 2014, 35(3): 558-565.
- [11] 黄宵宁, 张真良. 直升机巡检航拍图像中绝缘子图像的提取算法[J]. 电网技术, 2010, 34(1): 194-197.
HUANG X N, ZHANG ZH L. A method to extract insulator image from aerial image of helicopter patrol[J]. Power System Technology, 2010, 34(1): 194-197.
- [12] 赵振兵, 徐磊, 戚银城, 等. 基于 Hough 检测和 C-V 模型的航拍绝缘子自动协同分割方法[J]. 仪器仪表学报, 2016, 37(2): 395-403.
ZHAO ZH B, XU L, QI Y CH, et al. Automatic co-segmentation method for aerial insulator based on Hough detection and C-V model [J]. Chinese Journal of Scientific Instrument, 2016, 37(2): 395-403.
- [13] 姚春羽, 金立军, 闫书佳. 电网巡检图像中绝缘子的识别[J]. 系统仿真学报, 2012, 24(9): 1818-1822.
YAO CH Y, JIN L J, YAN SH J. Recognition of insulator string in power grid patrol images [J]. Journal of System Simulation, 2012, 24(9): 1818-1822.
- [14] 刘建友, 李宝树, 全卫国. 航拍绝缘子图像的提取和识别[J]. 传感器世界, 2010, 15(12): 22-24.
LIU J Y, LI B SH, TONG W G. Extraction and recognition of aerial insulator image [J]. Sensor World, 2010, 15(12): 22-24.
- [15] 王森, 杜毅, 张忠瑞. 无人机辅助巡视及绝缘子缺陷图像识别研究[J]. 电子测量与仪器学报, 2015, 29(12): 1862-1869.
WANG M, DU Y, ZHANG ZH R. Study on power transmission lines inspection using unmanned aerial vehicle and image recognition of insulator defect [J]. Journal of Electronic Measurement & Instrumentation, 2015, 29(12): 1862-1869.
- [16] 姜浩然, 金立军, 闫书佳. 航拍图像中绝缘子的识别与故障诊断[J]. 机电工程, 2015, 32(2): 274-278.
JIANG H R, JIN L J, YAN SH J. Recognition and fault diagnosis of insulator string in aerial images [J]. Journal of Mechanical & Electrical Engineering, 2015, 32(2): 274-278.
- [17] 黄凯奇, 任伟强, 谭铁牛. 图像物体分类与检测算法综述[J]. 计算机学报, 2014, 37(6): 1225-1240.
HUANG K Q, REN W Q, TAN T N. A review on image object classification and detection [J]. Chinese Journal of Computers, 2014, 37(6): 1225-1240.
- [18] XU B, WANG N, CHEN T. Empirical evaluation of rectified activations in convolutional network [J]. Computer Science, 2015, arXiv:1505.00853.
- [19] HINTON G E, SRIVASTAVA N, KRIZHEVSKY A, et al. Improving neural networks by preventing co-adaptation of feature detectors [J]. Computer Science, 2012, 3(4): 212-223.
- [20] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C]. Proceedings of the 32nd International Conference on Machine Learning, 2015: 448-456.
- [21] ACHANTA R, SHAJI A, SMITH K, et al. SLIC superpixels compared to state-of-the-art superpixel methods [J]. IEEE Transactions on Pattern Analysis &

- Machine Intelligence, 2012, 34(11):2274-2282.
- [22] QIN Y, LU H, XU Y, et al. Saliency detection via Cellular Automata [C]. Computer Vision and Pattern Recognition, IEEE, 2015:110-119.
- [23] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2012, 25(2):2012.
- [24] ZEILER M D, FERGUS R. Visualizing and understanding convolutional networks [C]. Computer Vision - ECCV 2014. Berlin: Springer International Publishing, 2013:818-833.
- [25] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]. IEEE Conference on Computer Vision and Pattern Recognition, IEEE Computer Society, 2015: 1-9.
- [26] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. Computer Science, 2014, arXiv:1409.1556.
- [27] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [28] UIJLINGS J R R, SANDE K E A V D, GEVERS T, et al. Selective search for object recognition [J]. International Journal of Computer Vision, 2013, 104(2):154-171.
- [29] KUO W, HARIHARAN B, MALIK J. Deepbox: Learning objectness with convolutional networks [C]. International Conference on Computer Vision, IEEE, 2015:2479-2487.
- [30] GIRSHICK R. Fast R-CNN[C]. International Conference on Computer Vision, IEEE, 2015:1440-1448.
- [31] WANG L, LU H, XIANG R, et al. Deep networks for saliency detection via local estimation and global search[C]. Conference on Computer Vision & Pattern Recognition, IEEE, 2015:3183-3192.
- [32] 李岳云, 许悦雷, 马时平, 等. 深度卷积神经网络的显著性检测[J]. 中国图象图形学报, 2016, 21(1): 53-59.
LI Y Y, XU Y L, MA SH P, et al. Saliency detection based on deep convolutional neural network[J]. Journal of Image & Graphics, 2016. 21(1):53-59.
- [33] HE S, LAU R W H, et al. SuperCNN: A superpixelwise convolutional neural network for salient object detection[J]. International Journal of Computer Vision, 2015, 115(3):330-344.
- [34] ACHANTA R, SHAJI A, SMITH K, et al. SLIC superpixels compared to state-of-the-art superpixel methods[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2012, 34(11):2274-2282.
- [35] JIA Y, SHELHAMER E, DONAHUE J, et al. Caffe: Convolutional architecture for fast feature embedding[C]. International Conference on Multimedia, ACM, 2014:675-678.
- [36] FELZENSZWALB P F, GIRSHICK R B, MCALLESTER D, et al. Object detection with discriminatively trained part-based models [J]. IEEE Transactions on Software Engineering, 2010, 32(9):1627-45.
- [37] DALAL N, TRIGGS B. Histograms of oriented gradients for human detection[C]. IEEE Conference on Computer Vision & Pattern Recognition, 2013:886-893.

作者简介



陈庆, 2013 年于西南石油大学获得学士学位, 现为电子科技大学在读研究生, 主要研究方向为模式识别与机器学习。

E-mail: cindy_chen258@163.com

Chen Qing received B. Sc. from Southwest Petroleum University in 2013. Now she is a M. Sc. candidate in University of Electronic Science of China. Her main research interest includes pattern recognition and machine learning.



闫斌, 1998 年于重庆大学获得学士学位, 2005 年和 2009 年于电子科技大学获得硕士学位和博士学位, 现为电子科技大学讲师, 主要研究方向为模式识别、无人机控制与导航、无线传感网。

E-mail: uestyan@163.com

Yan Bin received B. Sc. from Chongqing University in 1998, M. Sc. and Ph. D. both from University of Electronic Science and Technology of China in 2005 and 2009, respectively. Now he is a lecturer in University of Electronic Science and Technology of China. His main research interests include pattern recognition, control and navigation of UAV and wireless sensor network.



叶润, 2010 年于安徽大学获得学士学位, 2013 年于电子科技大学获得硕士学位, 现攻读电子科技大学博士学位, 主要研究方向为无线传感网、路由协议和定位算法、网络可靠性。

E-mail: Yr618@126.com

Ye Run received B. Sc. from Anhui University in 2010 and M. Sc. from University of Electronic Science and Technology of China in 2013, respectively. Now he is Ph. D. candidate in University of Electronic Science and Technology of China. His

main research interests include wireless sensor networks, routing protocol and position algorithm and network reliability.



周小佳,分别在1991年和1994年于电子科技大学获得学士学位和硕士学位,1997年于重庆大学获得博士学位,现为电子科技大学副教授,主要研究方向为无线传感网、电力系统自动化和分布式计算。

E-mail:zhouxj@uestc.edu.cn

Zhou Xiaojia received B. Sc., M. Sc. from University of Electronic Science and Technology of China in 1991, 1994, and Ph. D. from Chongqing University in 1997. Now he is an associate professor in University of Electronic Science and Technology of China. His main research interests include wireless sensor networks, power system automation and distributed computing.

罗德与施瓦茨推出具业界领先的相位噪声性能和高输出功率的高端模拟射频和微波信号发生器

频率范围高达20 GHz的R&S SMA100B是市面上领先的模拟信号发生器。它产生的信号具有极低的相位噪声和超高的输出功率,同时还具备良好的谐波抑制性能。工程师无需再在输出功率和无杂散动态范围两个指标之间做出取舍。R&S SMA100B设计为满足RF半导体,无线通信和军工应用。

R&S SMA100B在所有频率上提供最低相位噪声的纯净信号(1 GHz,20 kHz频偏,-152 dBc/Hz)。6 GHz版本的仪器可以产生高达38 dBm的射频输出功率,20 GHz版本的仪器可在微波频段产生高达32 dBm的输出功率。在整个频率范围内谐波分量都是极低的,当在6 GHz以上频段输出18 dBm的输出功率时,谐波分量甚至显著低于-70 dBc。输出信号为1 GHz时,杂散分量低于-110 dBc。

罗德与施瓦茨公司信号源,音频分析仪和功率计部门副总裁 Andreas Pauly 表示“R&S SMA100B让客户可以验证他们被测件的真实性能,因为信号源本身性能不会影响测试结果,R&S SMA100B提供前所未有的优异性能,帮助我们客户取得将产品推向市场的技术领先地位”。

用于高精度ADC和DAC测试的极纯净信号

最新水平的ADC和DAC测试需要相位噪声和宽带噪声最低的绝对纯净信号,还能够额外提供除了提供极度纯净的模拟RF信号,R&S SMA100B还是世界上唯一能够提供额外第二路,可独立设置,极度纯净和高达6GHz同步时钟信号的模拟信号源。因此,用户可以使用单台模拟信号源量化其ADC。时钟频综输出信号具备极低的宽带相位噪声(100 MHz,-175 dBc/Hz,30 MHz频偏),可以用来测试现代ADC的信噪比,也使R&S SMA100B成为了测量高性能ADC的理想参考。

Analog Devices公司,高速A/D转换器测试总监 Ron Goga 表示,“罗德与施瓦茨之前推出它的极低相噪R&S SMA100A信号发生器,在过去十年里一直尽最大能力帮助我们评估、测试和定义我们世界级的A/D转换器,作为它的继承者,SMA100A具有更低的相位噪声”,“两家公司保持着紧密合作,具有20GHz极度纯净信号的模拟RF信号源R&S SMA100B的及时发布与Analog Devices最新射频系列转换器的发布紧密吻合,该转换器系列包含新双3GSPS 14位A/D转换器AD9208和双12GSPS 16位D/A转换器AD9172,最先进的R&S SMA100B使我们能够在最耀眼的舞台继续展示我们的RF数据转换器”。

R&S SMA100B同样是量化DAC时钟源的完美选择。发生器极低的相位噪声产生最小化的信号抖动从而

不会影响DAC的实际测试结果。

满足苛刻应用最好的雷达信号源

R&S SMA100B拥有强大的脉冲调制器和发生器,具备极短的上升/下降时间和高达90 dB的开关比,最新的数字,高精度自动电平控制(ALC)保证窄脉冲的峰值功率电平是高度精确和可重复。闭环电平控制可以被应用在脉宽大于100 ns的场景。这些特性使得在测试具备无与伦比的准确的先进雷达接收机在苛刻的脉冲场景中测试成为可能。

在雷达系统整机组装前,极纯净的本地振荡器信号通常需要替代验证。R&S SMA100A由于其可提供具备超低近相位噪声(10 GHz,10 Hz频偏,-83 dBc/Hz)的高电平信号,是替代本振的理想解决方案。

高质量,先进的基站需要严格的阻塞测试

基站接收机的选择性有许多准则评估,包括对强干扰抑制的有多好。当使用SMA100B模拟带内和带外干扰时,仪器的超低相位噪声选件保证了模拟干扰源的相位噪声和宽带噪声对有用信号的影响降至最低。借助R&S SMA100B的极佳信号质量,基站真实的干扰抑制性能可以被准确的衡量(例如:10 GHz宽带噪声,30 MHz频偏,低于-160 dBc/Hz)。

无磨损,电子步进衰减器和最高输出功率用于生产环境

超高的输出功率选件使R&S SMA100B能够提供高达38 dBm的输出功率,在自动化测试环境中消除外置放大器的需求,在20 GHz仪器里,集成的、无磨损的电子步进衰减器现在作为标配,罗德与施瓦茨最大化提升了在需要无数次电平周期切换的测试系统中的使用寿命,而几乎不需考虑仪器的磨损。这种解决方案还提供了在微波信号源中有史以来极快的电平设置时间。

R&S Legacy Pro 即插即用

R&S SMA100B包含了R&S Legacy Pro程序,该程序可用来轻松替代自动化测试系统中罗德与施瓦茨和其他制造商的信号发生器,而无需修改测试软件。

欲了解更多信息,请点击:www.rohde-schwarz.com/ad/press/purest-signal