

[电力设备]

基于深度神经网络的电力设备图像识别探究

文/国网福建省电力有限公司检修分公司 何志甘 范彦琨 张锦吉

随着电力系统智能化水平的持续提升，越来越多的变电站开始利用远程传输过来的图像与视频做出对相关设备运行情况的评价。在电力系统之中引入图像与视频信息是一种巨大的技术进步，可以促进电力系统智能化水平的提升。基于深度神经网络的电力设备图像识别进行分析，希望能够对深度神经网络有比较全面深入的了解。

现阶段，在进行电力设备的识别与分析时，越来越多的专家学者主要针对海量非结构化视频以及图像数据流来展开分析，这依旧处于初期阶段；如何实现多媒体数据的利用，从数据之中寻找相应的规律与特点，并且直接将其提取出来，以此来实现对目标的识别，成为需要解决的关键性问题。作为解决这一问题的关键，机器学习也从原本的浅层学习逐渐发展到深度学习，从而实现对关键问题的进一步研究。

深度神经网络介绍

深度神经网络作为机器学习的一种技术，属于一种判别模型，其本身具有至少一个隐层的神经网络，可以使用反向传播算法来训练。深度神经网络中的深度是指一系列连续表示层，在数据模型之中包含了多少层就称之为模型的深度。利用这些层可以实现数据高层抽象。

基于深度神经网络的电力设备图像识别模型构建

1. 图像采集和预处理

(1) 图像采集

电力系统巡检部门在采集电力设备中基本上都

是利用采集系统，系统中的基本载体在于机器人、无人机等，通过搭建高清摄像机、红外成像仪等图像设备，实现信道编码技术、图像处理技术等有关技术于一体，这样就可以通过无线的方式，直接将拍摄的图像传输到对应的管理中心，其实际的采集流程如图1所示。




图1 电力设备图像采集流程

(2) 预处理

采集的图像还无法直接地进行识别处理，主要是因为其图像格式与质量都无法直接匹配对应的标准要求，所以需要实施对应的预处理。

1) 灰度化处理。图像灰度化，也就是要求直接将图像转化成为灰度的图像。在原始采集的图像中会有色彩因素的存在，这样会增加后续的处理计算量。但是通过灰度化的处理，就可以减少数据量，从而可以避免彩色因素的干扰。首先，在提取处理中，可以考虑分量法的运用

$$\begin{cases} Y_1(i, j) = R(i, j) \\ Y_1(i, j) = G(i, j) \\ Y_2(i, j) = G(i, j) \\ Y_3(i, j) = B(i, j) \end{cases} \quad (1)$$

式中， $R(i, j)$ 、 $G(i, j)$ 和 $B(i, j)$ 表示 (i, j) 的色彩分量。

提取处理基于彩色图像的三原色像素点最大值之后，就可以得到

$$Y(i, j) = \max[R(i, j), G(i, j), B(i, j)] \quad (2)$$

利用平均值法，获取其对应的彩色图像平均值

$$Y(i, j) = \frac{R(i, j) + G(i, j) + B(i, j)}{3} \quad (3)$$

基于上述的分析，通过加权平均法直接将其转化成为灰度图像

$$Y(i, j) = 0.30R(i, j) + 0.59G(i, j) + 0.11B(i, j) \quad (4)$$

其中，3个色彩分量权值分别是0.30、0.59和0.11。

2) 电力设备图像滤波。在采集电力设备图像过程中，由于各种因素的影响，可能会导致噪声点存在于原始图像上，这样会使得图像中信息模糊，影响后期的识别。所以，为了进行电力设备图像的去噪，可以利用均值滤波法，通过滤波窗口来实现逐像素的移动，通过串口的像素平均值，就可以直接替代原本图像的灰度值。

在均值算法滤波窗口之中，可以实现对应的降噪处理

$$G(x, y) = \frac{\sum_{(i, j) \in s} f(i, j)}{N} \quad (5)$$

式中， $G(x, y)$ 表示滤波去噪之后的电力设备图像； $f(i, j)$ 表示中心点像素为 (i, j) 的原始图像； s 表示所有邻域像素集合； N 表示 s 内像素点的总数。

在进行降噪之后，可以有效抑制噪声，但是因为模糊化边缘细节信息，所以在去噪之后还要做好图像边缘的增强处理。具体就是进行自适应增强，实现对电力设备图像的精准识别。

2. 基于深度神经网络的电力设备图像识别

(1) 特征提取与融合

在开展识别之前，需要实现电力设备图像特征对应的提取，如纹理、颜色和新传等，基于特征相对分散的分析，需要实现特征对应的融合处理，以此来满足等待识别的综合特征的相对对应构建。在引入权重融合相似度测度之后，再与特征相互融合起来，这样就可以判定其对应的相似度问题，然后计算其权重

$$\begin{aligned} \text{sim}(Q, D) &= \alpha_c \left(\sum_{i=1}^N \beta_c^i |C_i^Q - C_i^D| \right) + \alpha_r \left(\sum_{i=1}^M \beta_r^i |T_i^Q - T_i^D| \right) \\ &= \alpha_s \left(\sum_{i=1}^Z \beta_s^i |S_i^Q - S_i^D| \right) \end{aligned} \quad (6)$$

式中， α_c 、 α_r 和 α_s 表示限制3个特征对于相似性测度的实际共享度； β_c^i 、 β_r^i 、 β_s^i 表示限制 N 个颜色特征向量、 M 个纹理特征向量以及 Z 各形状特征的总相似性测度的实际共享度； Q 表示等待检索图像； D 表示数据库图像。

(2) 模型构建

对于提取特征，还要求能够实现数据库图像特征的直接匹配，这样就可以有效地识别各种设备。基于深度神经网络算法的卷积神经网络，实现识别模型的构建。具体的组成如图2所示。




图2 模型的系统组成

假设电力设备图像目标函数为

$$F(x) = \arg \min_{\omega} \frac{1}{c} \sum_{i=1}^c v(H_l(x_i, \omega_l), y_i) \quad (7)$$

式中， c 表示图像数量； H_l 表示激活函数； ω_l 表示权

值矩阵； ν 表示损失函数。

在获取电力设备图像目标函数之后，就能够获取最优解

$$\frac{\partial l}{\partial \varpi_l} = -\frac{1}{c} [y_l - H_l(d_l, \varpi_l)] \times H_l'(d_l, \varpi_l) + \eta \varpi_l \quad (8)$$

式中， d_l 表示电力设备图像输入值； η 表示正则化系数。

以此为基础做好图像的识别，构建对应的识别模型

$$g(a, b) = \frac{1}{c} \sum_{i=1}^c (b_i - \ln[H_l(a_i, b_i)]) + \eta \sum_{i=1}^l \sum_{j=1}^l \|\varpi_i\|^2 \quad (9)$$

相比其他模型，这一模型训练需要的样本数量较少，并且有更快的收敛速度，所以识别的优势非常大。

3. 实例分析

(1) 实验环境

为了进一步验证方法的可靠性，要求做好实验分析。基于Tensor Flow卷积神经网络训练与测试软件的使用，搭配数字摄像头，就可以针对图像做好对应的采集与处理。

(2) 实验参数

对于常见的电力设备图像，具体的样本分布见表1。

表1 样本图像

电力设备	特征图尺寸	训练样本/幅	测试样本/幅
绝缘子	30×30	50	20
断路器	20×25	50	20
变压器	27×27	50	20
输电线铁塔	25×30	50	25
输电线电杆	30×35	50	30

(3) 实验方案

在实验环节，主要是考虑到对比本方法的运用与双通道图像电力设备的智能化识别以及对应的变电站设备图像识别方法之间的相互分析。通过对比处理，可以明确准确度计算公式为

$$mAP = \frac{\sum AP_i}{N} \quad (10)$$

式中，AP为第*i*图像的平均识别准确率；*N*代表类别，*N*=5。

(4) 实验结果

1) 准确度分析。针对模型可靠性进行验证，在实验条件相同的前提下分析具体的识别准确度，如

图3所示。




图3 不同方法的识别准确度分析

基于图3分析，本方法可以满足99%的准确度识别处理，其余两种识别准确度明显偏低，这主要是因为所使用的方法能够实现滤波降噪。

2) 耗时分析。在满足电力设备图像识别准确度的基础上对其进行耗时分析，结果如图4所示。

通过图4可知，本文耗时局限于5 s之内，其余方法存在较大的耗时波动性。这主要是因为本方法选择了电力设备图像特征的融入，可以满足识别耗时有效缩短的要求，进而对提出方法的高效性进行分析。




图4 不同方法的耗时分析

结语

随着时代发展，针对现阶段的电力设备图像识别需要合理采取各种有效技术来满足实际的需求。因此，通过本文对基于深度神经网络的电力设备图像识别进行处理，为后续研究提供参考和借鉴。EA

(收稿日期：2021-10-08)