

# 基于卷积递归网络的电流互感器红外故障图像诊断

林颖, 郭志红, 陈玉峰

(国网山东省电力公司电力科学研究院, 山东 济南 250002)

**摘要:** 电力大数据中日益增多的非结构化数据为以人工诊断为主的传统处理方式提出了新的挑战。红外故障图像作为一种典型的非结构化数据, 对于电力大数据的研究有着至关重要的作用。为了达到自动处理海量红外故障图像的目的, 提出了一种基于卷积递归网络的电流互感器红外故障图像诊断方法。对红外故障图像首先进行超像素分割并利用其色度信息提取温度异常区域; 然后采用两级联合卷积-递归神经网络, 对大量样本信息进行训练学习来指导设备故障部位识别; 最后依据部位信息对故障进行分类。实验结果表明, 该算法鲁棒性较强, 准确性较高, 有效地提高了红外检测效率, 为非结构化数据的特征提取分析提供了坚实的基础。

**关键词:** 红外故障分析; 电力大数据; 超像素分割; 深度学习; 卷积递归神经网络

## Convolutional-recursive network based current transformer infrared fault image diagnosis

LIN Ying, GUO Zhihong, CHEN Yufeng

(State Grid Shandong Electric Power Research Institute, Jinan 250002, China)

**Abstract:** Increasing unstructured data of big data in electric system puts forward a new challenge to traditional manual processing mode. As a typical kind of unstructured data, the infrared image is very important for the research of big data in electric system. In order to automatically processing massive infrared fault images, this paper presents a convolutional recursive network based current transformer infrared fault image diagnosis method. The infrared fault images are first segmented by super pixel segmentation method and then we take advantage of the hue information to extract the temperature anomaly area; secondly, a two-level joint convolution recursive neural network is adopted, the fault device position can be identified by training a large number of samples; finally, the fault information is confirmed according to the location information of fault classification. The experimental results show that, this algorithm has better robustness, higher accuracy, and can improve the efficiency of infrared diagnosis, which is also the foundation for the feature representation of unstructured data.

This work is supported by National High-tech R & D Program of China (863 Program) (No. 2015AA050204).

**Key words:** infrared fault image analysis; big data in electric system; superpixel segmentation; deep learning; convolutional-recursive neural network

中图分类号: TM452 文献标识码: A 文章编号: 1674-3415(2015)16-0087-08

## 0 引言

有关统计资料表明, 电力系统中超过半数以上的电气设备故障都是连接松动、接触不良、泄露电流、漏磁等造成的发热引起的<sup>[1]</sup>。通过分析红外热像仪得到的红外故障图像, 可以分析判断出设备可能存在的各种缺陷。现有工作模式下, 红外图像故障识别主要以人工识别为主, 对人员的专业素质要

求高, 存在着人为因素影响大、工作效率低等缺陷。随着智能变电站和变电站巡检机器人<sup>[2]</sup>的进一步发展和普及, 海量的红外故障图像涌入等待分析, 此时仅依靠人工分析显然已经不能满足需求。而采用计算机的辅助分析手段对采集到的红外图像进行自动提取、识别、分析, 可以减轻劳动强度、减少对技术人员的依赖; 更有利于实现图像的数据化, 便于进行横向和纵向的统计分析。

在此需求下, 近年来, 一些自动检测电气设备红外图像的方法陆续被提出<sup>[3-8]</sup>, 另外一些研究者通过增加可见光图像等其他来源来提供辅助信息, 从

而获得更加可靠的分析结果<sup>[9-10]</sup>。文献[3]中仅对红外图像进行了基本的增强处理，设备区域的识别和选取仍然依靠手工进行，所以并不完全具备自动检测的功能；文献[4-5]采用常见的图像分割方法分水岭、K 均值聚类等目标图像进行分割，需要参数调整，且无法对分割设备做有效分析，适应性较差；文献[7]已经具备了红外图像故障自动诊断的雏形，但是其所用方法较为简单，均为基本的图像处理算法，实验结果仅针对少量数据进行，可靠性较低。可以看出，现有的大部分红外图像故障分析方法都停留在简单的图像分割的基础上，没有针对红外故障图像本身的成像特性进行分析。事实上，红外故障图像的成像和普通的可见光图像并不相同，具有其特有的性质。

另外，上述方法大多没有对故障产生的位置、类别等信息进行进一步的分类和梳理。而通过故障区域呈现出的特征识别出该故障发生部位，是一个典型的模式分类问题。传统的分类方法多采用机器学习的手段，先利用典型特征描述方法包括 SIFT<sup>[11]</sup>，SURF<sup>[12]</sup>，HOG<sup>[13]</sup>等，对训练样本进行低层次特征(角点、边缘、纹理等)提取，然后再对这些特征进行训练来进行分类操作。但是，这些特征描述方法通常仅适用于具有某类特性的图像数据，而红外故障图像到底适合哪一类的特征描述方法，则需要人工选择。该过程是一个启发式的过程，最终结果的好坏很大程度上依靠的是经验和运气。在这一前提下，可以提供非监督式学习的深度学习方<sup>[14]</sup>更适用于这样一种需求。深度学习的实质是通过构建具有很多隐层的机器学习模型和训练数据，自发地学习更高层次的特征，从而最终提升分类或预测的准确性，和传统的学习方法相比，更能够刻画数据丰富的内在信息。

依靠对红外故障图像的成像特性分析以及深度学习的算法研究，本文以电流互感器红外故障图像为例，提出了基于深度学习的电流互感器红外故障图像分析方法。首先利用超像素分割方法和 HSV 颜色空间提取、校验故障区域，然后通过设计的深度学习模型对故障位置进行分类识别，根据故障的不同位置确定故障信息，可应用于红外诊断实验的辅助分析、生产管理系统(PMS)的历史红外诊断数据的梳理、校验，也为电力大数据分析领域的非结构化数据结构化提供了研究基础。

### 1 基于超像素的 HSV 空间区域分割

在用红外热像仪采集图像的过程中，为了保障故障分析的准确性，会要求实验人员尽量保证故障

区域位于输出图像的中心位置，而且占据画面的大部分空间，而且尽量将温度范围调小，使得故障区域和其背景区域在呈现图像中对比度更高。一张典型的红外故障图像通常具有以下几点特征：

- (1) 整个图像范围内成像噪声较大，成像主体为故障设备；
- (2) 故障区域与背景区域的特征具有较大差异性，区域内部性状相近；
- (3) 故障区域温度较高，呈现黄色或接近白色，以故障点为中心温度逐步发散，区域内平均亮度较高、轮廓较为平滑、位置接近图像中心。

由此，在对该图像进行处理前，需要对图像进行平滑预处理来减小噪声的影响，然后通过超像素分割方法合并性质相近的像素点，便于更好地统计分析区域特性，在此基础上再依据颜色分布利用 HSV 空间进行提取。

#### 1.1 基于超像素的 HSV 空间分割

分割的主要需求是为了合并性质相似像素区域，便于区域性分析，对算法的分割精确度要求相对宽松。因此，此处选择经典的 Turbopixel<sup>[15]</sup>超像素分割方法。将分割后的区域记为  $R_i, i=1,2,3,\dots,n$ ， $n$  为分割个数。

然后，利用 HSV 颜色空间进行区域提取，和 RGB 等其他颜色空间相比，HSV 空间(分别代表色度、饱和度和亮度)可以更准确地感知颜色联系，不同的  $H$  值可以指代不同的颜色， $H$  值分布平面图如图 1 所示。对故障区域来说，我们更关心的是颜色偏黄和接近白色的区域，黄色分量的色彩特点为  $R \approx G \gg B$ ，而白色分量  $R \approx G \approx B \approx 255$ 。

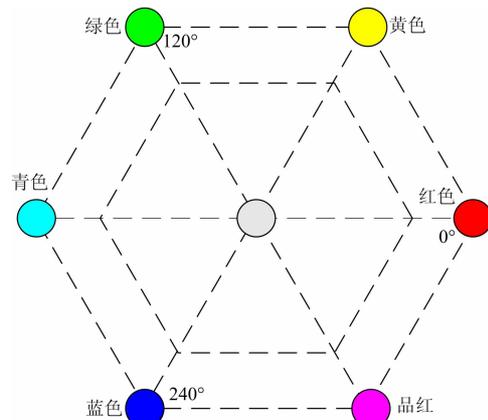


图 1 色度色相分布示意图

Fig. 1 Hue chromacity plane

由此，将每个区域  $R_i$  内的颜色分量以其区域内的均值  $[\bar{r}_i, \bar{g}_i, \bar{b}_i]$  替代，为了突出待分割的区域，修

改标准的  $H$  值传统计算公式并进行归一化, 得到新的  $H$  值计算公式为

$$H = \begin{cases} 1 & \text{if } R > 180, G > 180, B > 180 \\ \frac{1}{6} \left( 4 + \frac{G-B}{\max-\min} \right) & \text{else if } R = \max \\ \frac{1}{6} \left( 2 + \frac{B-R}{\max-\min} \right) & \text{else if } G = \max \\ \frac{1}{6} \frac{R-G}{\max-\min} & \text{else if } B = \max \end{cases} \quad (1)$$

将分割阈值设为

$$H > 0.65; S > 0.5 \text{ or } S < 0.12; V > 200。$$

### 1.2 故障区域验证

由于环境设备的影响, 在大多数情况下, 分割之后仅剩故障区域的情况较少。此时需要对留下的多个区域做进一步的筛选、梳理。

通过上文分析的故障区域几点特性采用如下三个特征量来描述区域属性。

(1) 平均亮度  $\bar{I}_{R_i}$ : 以归一化的区域内灰度的平均值表示。

(2) 凹凸度  $S_{R_i}$ : 通过该区域面积(即像素点个数)  $N_{R_i}$  和该区域的最小凸边形的面积  $C_{R_i}$  得到。

$$S_{R_i} = N_{R_i} / C_{R_i} \quad (2)$$

(3) 中心距离  $d_{R_i}$ : 取区域边缘到图像中心位置的最小值。

结合三个特征量, 将得到函数  $F$  最大值的区域选择为提取出的故障区域, 记为  $R_s$ 。

$$F = \bar{I}_{R_i} S_{R_i} / d_{R_i} \quad (3)$$

### 1.3 设备影响区域分割

大部分的故障区域仅为一个故障点, 单纯对此区域进行分析无法看出其影响位置和故障类型, 因此需要分割出故障影响的设备位置。在红外图像中, 非设备区域可以看做非常明显的背景区域, 和设备区域有明显区隔。因此, 仅利用简单的阈值分割可以得到含有设备区域的二值图像, 在此二值图中故障区域和设备区域是连通的, 以故障区域为中心得到故障的设备影响部位。具体操作如下:

(1) 采用大津法<sup>[16]</sup>(otsu)对灰度图像进行二值分割, 得到二值图像  $I_b$ ;

(2) 查找  $I_b$  中包含故障区域的连通区域  $R_o$ , 查找条件满足  $R_o \cap R_s > 0.8R_s$ ;

(3) 从  $R_s$  的最小外接矩形边缘出发, 以  $R_o$  的宽高比确定步长, 设置停止条件:  $l_{\text{zero}} / l_{\text{all}} > 0.5$ 。其中  $l_{\text{zero}}$  为四个边框的灰度值为 0 的像素个数,  $l_{\text{all}}$  为边

框总长度。将能够得到的故障设备部位记为  $R_f$ 。

## 2 基于深度学习的故障区域识别

通过分析输变电设备红外典型故障图和 DLT 664-2008 带电设备红外诊断应用规范, 可以将电流互感器的主要故障部位和致热原因分为以下三种:

- (1) 接头发热, 为电流致热型。
- (2) 内连接发热, 为电流致热型。
- (3) 套管内绝缘发热, 为电压致热型。

其余故障出现的情况不多, 可用样本范例较少, 因此本文仅以这三种情况作为故障部位、类型的分类依据, 将用于训练样本集类别设为三种。由于故障产生部位唯一确定故障的致热原因为电压致热型或电流致热型, 所以在识别出故障部位后即可得到对应的故障类型。

本文采用如图 2 所示的两级卷积递归神经网络<sup>[17]</sup>进行学习, 输入样本首先经过一级卷积网络, 然后将得到的特征图输入第二级的多层递归神经网络中, 递归神经网络的层数由设置的参数决定, 最终全连接输出到一个 softmax 分类器中。

### 2.1 滤波器生成

将输入样本的尺寸转换为  $m \times n$ , 滤波器的尺寸设为  $r \times r$ , 滤波器个数为  $K_1$ , 滤波器的预训练通过 K 均值聚类<sup>[18]</sup>来无监督实现。随机选取样本中  $N$  个  $r \times r$  的小块组成维度为  $r^2 \times N$  的输入特征向量, 利用 K 均值聚类来无监督地学习该特征集的  $K_1$  个中心值, 即相当于求取了  $K_1$  个  $r \times r$  的特征值, 作为滤波器的卷积核使用。

和其他无监督训练方法<sup>[19-20]</sup>相比, K 均值需要调整的参数仅有聚类个数  $K_1$ , 因此在待处理的特征维度不高的情况下, 具有更好的效果和算法效率<sup>[21]</sup>。具体实现过程参见文献[18]中的描述。

### 2.2 卷积神经网络层

#### 2.2.1 卷积层

在得到滤波器后, 将卷积的步长设为  $s$ , 考虑卷积的边缘效应, 经过卷积层之后我们可以得到特征图的尺寸为  $(\frac{m-r}{s}+1) \times (\frac{n-r}{s}+1)$ , 个数为  $K_1$ 。

#### 2.2.2 采样层

假设输入的特征图尺寸为  $m_1 \times n_1$ , 即  $(\frac{m-r}{s}+1) \times (\frac{n-r}{s}+1)$ , 采样范围为  $r_1 \times r_1$ , 步长为  $s_1$ , 则采样后的特征图尺寸为

$$m_2 \times n_2 = (\frac{m_1-r_1}{s_1}+1) \times (\frac{n_1-r_1}{s_1}+1) \quad (4)$$

在经过第一级的卷积网络后的特征尺度为

$K_1 \times m_2 \times n_2$ 。在具体实现中，通常将待输入的图片归一化为  $m = n$ ，因此，简化特征图尺寸为  $m_2 \times m_2$ 。

### 2.3 递归神经网络层

在第二级网络中，每一层中所有特征向量一起连接组成下一层的特征，共享同一组权重，通过接受域的选择逐步降低特征维度。设滤波器的接收域为  $l \times l$ ，每层的递归神经网络(RNN)数量为  $K_2$ ， $W$  是二维的权重矩阵，大小为  $K_2 \times K_1 \times (K_1 \times l \times l)$ 。

在接受域无重叠的情况下，一层递归神经网络

之后每张特征图的维度降为  $\frac{m_2}{l} \times \frac{m_2}{l}$ ，之后每层都将维度降低  $l \times l$  倍，直到变为  $1 \times 1$ ，最终每张样本图像输出的单层特征维度为  $n_0 = K_2 \times K_1$ 。

本文提出多尺度的递归神经网络，将最后两层的特征同时输出的分类器中用于分类。因此每张特征图的输出特征维度应为  $K_1 \times (l \times l + 1 \times 1)$ ，每张样本图像输出维度为  $n_o = K_2 \times K_1 \times (l^2 + 1)$ 。

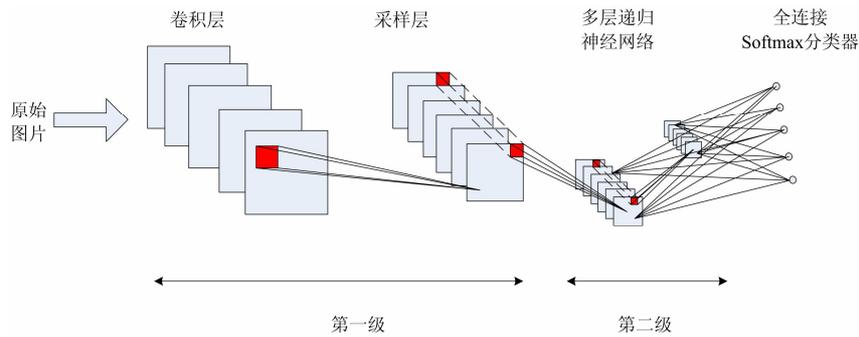


图 2 卷积递归神经网络结构

Fig. 2 Convolutional-recursive network

## 3 实验结果分析

### 3.1 算法精度分析

本节首先讨论分割算法的精度，然后讨论在本文设计的网络结构下，设置何种的参数可以得到更好的识别效果。

#### 3.1.1 分割算法精度

由于对于故障区域的分割识别并不局限设备类型，我们选取了生产管理系统(PMS)中上传的电流互感器、电压互感器、避雷器等设备故障图像共 300 张，手工标注其故障区域，得到的准确率 (Precision)和查全率(Recall)的结果如图 3 所示。

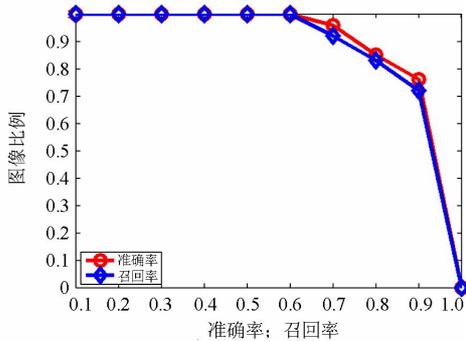


图 3 分割结果评价

Fig. 3 Precision and recall of the segmentation results

图 3 中每个点代表的意义是超过该点准确率或查全率(x 值)的图像比例(y 值)。例如，准确率第 8 组点(0.8,0.85)，代表的含义是准确率超过 0.8 的图像个数占总数量的 85%，因此两条曲线在 1 的时刻 y 值均为 0。

由于故障区域的影响范围每个人的理解各不相同，不同类型设备环境的复杂程度也不同，因此该精度验证在定量分析的基础上可以在一定程度上体现出该基于超像素的 HSV 空间分割方法的有效性。

#### 3.1.2 分类算法精度

深度学习在图像处理、视觉领域的识别效果已经在各类相关文章中得到了证实，因此本节的精度分析主要针对在现有的网络结构和样本数量下，如何设定  $K_1$  和  $K_2$  的合理取值，来取得效率和精度上的平衡。

本文将输入样本尺度设为  $67 \times 67$ ，滤波器大小为  $8 \times 8$ ，步长为 1，则卷积层后的特征图大小为  $60 \times 60$ ，采样层步长为 2，最终第一级输出每个特征图大小为  $27 \times 27$ ，将  $27 \times 27$  的特征图输入接受域为  $3 \times 3$  的递归神经网络，经过 3 层运算变为  $1 \times 1$ ；若仅输出单层特征，则最终的每个样本图像得到的特征维度为  $K_2 \times K_1$ ，若输出多层特征，则最终的每

个样本图像得到的特征维度为  $K_2 \times K_1 \times 10$ 。

对于待分类的三种故障类型, 每种类型有 3 000 张的训练集, 总的训练样本数为 9 000 张。用于测试的样本数量为 500 张。

(1) 首先固定  $K_1=128$ , 将  $K_2$  从 1 以增量 5 变化到 63, 分类精度如图 4(a)所示, 两条折线分别代表在此参数设置下采用单层特征和多层特征的结果精度。从图中可以看出, 多层特征和传统的单层特征相比, 精度较为稳定, 每层可以采用数量更少的  $RNN$  数量, 在  $RNN>30$  以后分类精度基本稳定。

(2) 仅考虑多层特征的算法效果, 固定  $K_2=32$ ; 变化  $K_1$ , 从 8 以步长 8 递增至 128, 得到的结果如图 4(b)所示。可以看出, 在  $K_1$  大于 64 之后可以得到较为稳定的分类结果。

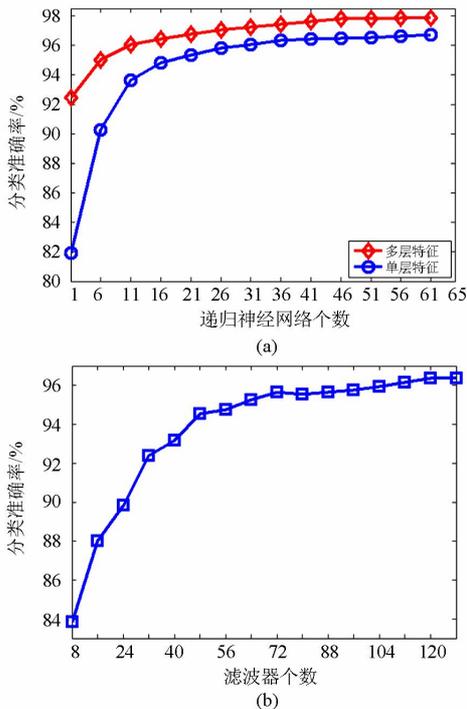


图 4 多层特征、单层特征结果比较

Fig. 4 Comparison results of multi-layer and single-layer features

由此, 我们将  $K_1$ 、 $K_2$  的参数设置为  $K_1=64$ ,  $K_2=32$ 。K 均值预先训练得到的滤波器如图 5 所示。

对样本库进行训练的过程可以看做整个分类问题的前期后台准备阶段, 在进行一次训练后, 仅会在积累了大量的新增样本后需要对特征进行阶段性更新, 其处理时间对分类应用效率的影响可以忽略。因此本文对样本训练时间并不做过多讨论。

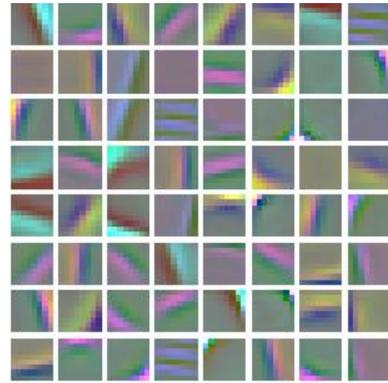


图 5 K 均值预训练滤波器结果

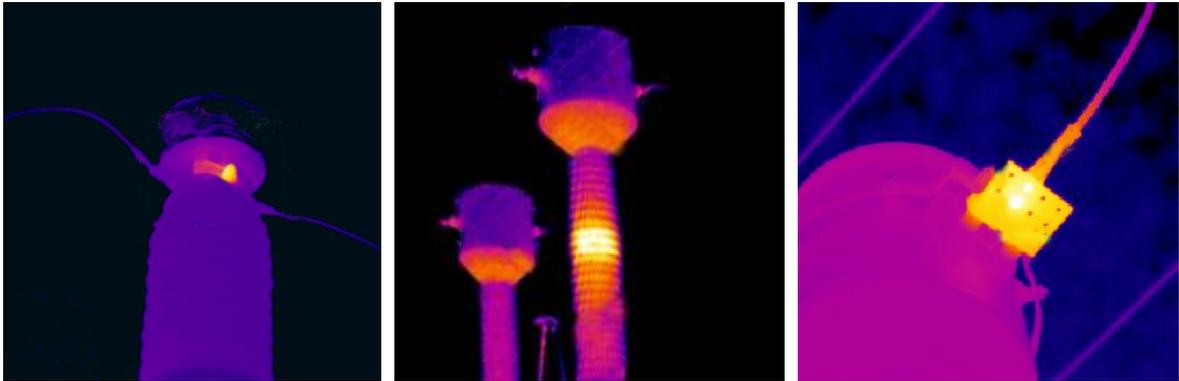
Fig. 5 Pre-trained Filters using K-means

### 3.2 算法分析

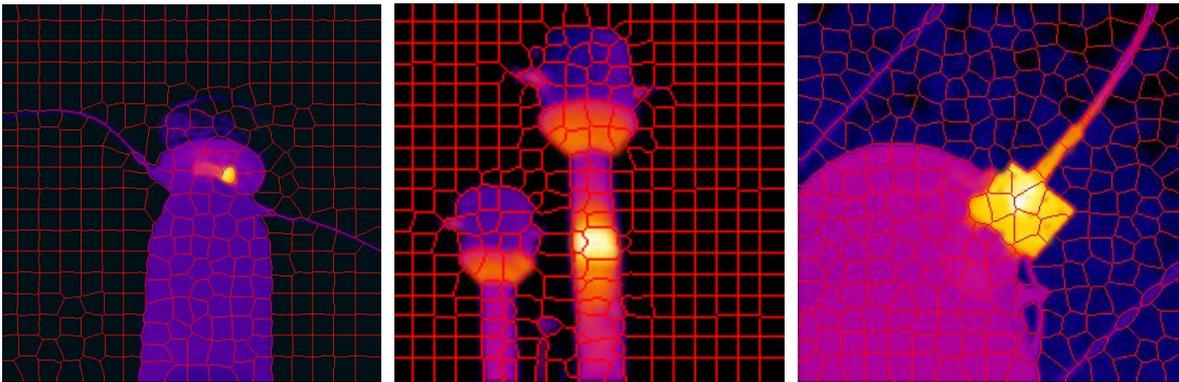
本文选取了三张不同部位的红外故障图像来展示整个算法流程, 如图 6 所示。其中图 6(a)为输入的红外图像, 图 6(b)为超像素分割结果, 图 6(c)为计算的  $H$  值灰度图, 图 6(d)为提取得到的故障区域, 图 6(e)为大津法分割结果, 图 6(f)为最终得到的故障区域和故障设备部位区域, 其中实线框为故障区域, 虚线框为设备部位区域。可以看出, 在超像素分割阶段, 分割算法可以将不同特性的区域进行区隔, 这也保证了色度灰度图像的平滑程度; 通过  $H$  值灰度图可以看出, 故障区域和其背景区域相比有较强的显著性; 将大津法的灰度图分割结果与故障区域分割结果结合, 可以较为清晰地对比出故障的设备影响部位。在最终的区域查找结果中, 第一张图由于设备的宽高比不同, 虚线边框呈现高度大于宽度的特性。而另外两张图由于故障区域接近设备区域外部, 因此在以故障区域外边延扩散查找时, 判定为设备影响区域, 两区域基本重合。

从整体的精度分析和结果展示来看, 本算法兼顾了不同类型红外故障图像的特性, 灵活性较高, 在得到足够样本量的支撑下, 可用于所有变电设备的红外故障图像自动诊断, 具有一定的鲁棒性。

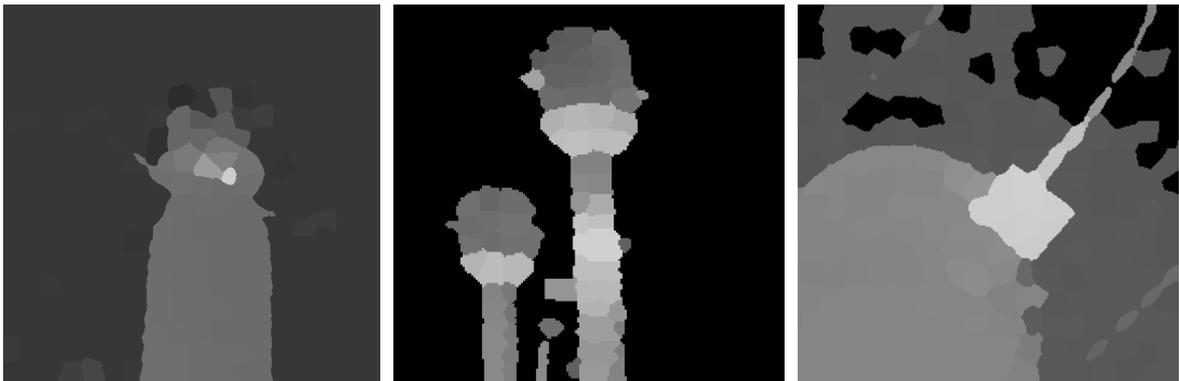
另外, 本算法并未涉及到红外故障图像的温度识别问题(红外图像的温度对应颜色棒区域本文未展示), 通过识别温度数字, 结合温度颜色棒得到颜色对应温度值, 对故障进行进一步的分析。从单纯的图像处理角度, 识别红外图像中标注的温度范围是一个数字识别问题, 本文中并不涉及。因此, 在得出致热原因后, 本文并没有对故障区域和设备区域的温度对比作进一步分析。



(a) 原图



(b) Turbopixel 分割结果



(c)  $H$  值灰度图



(d) 故障区域分割结果

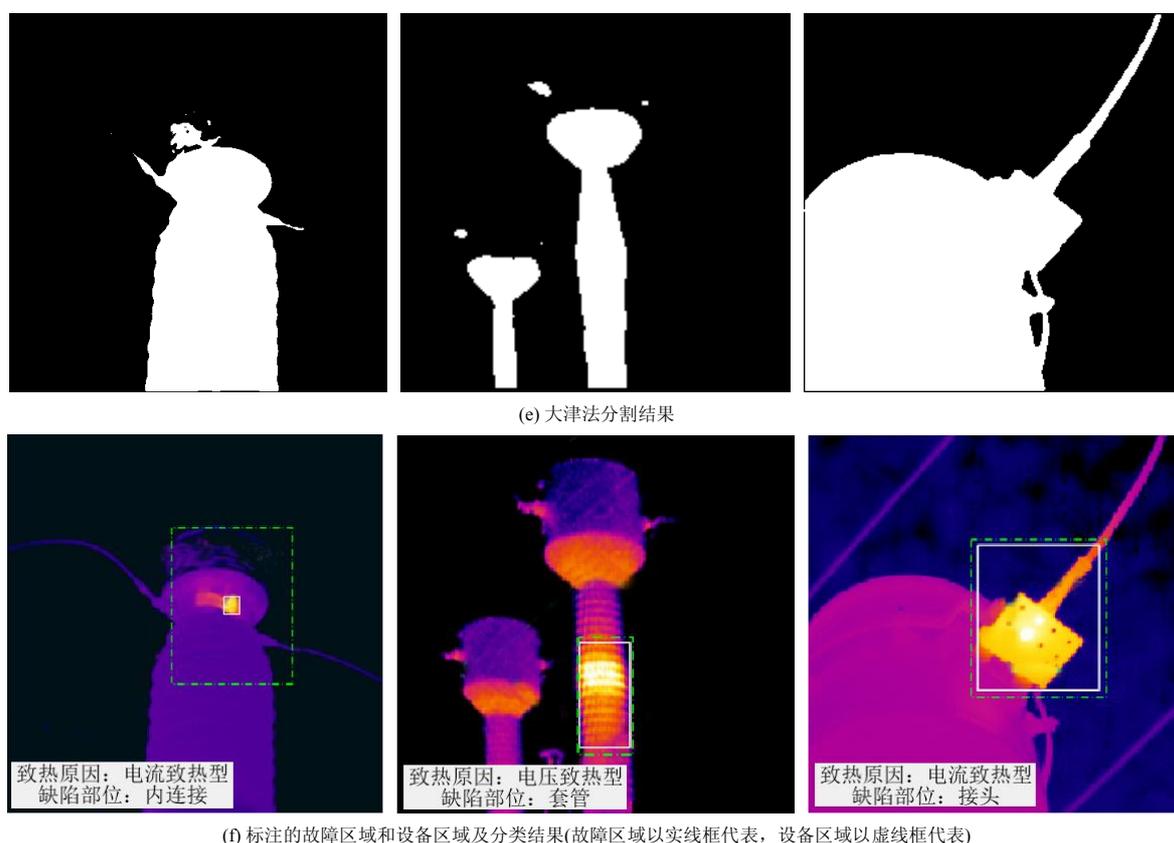


图6 算法流程示意图

Fig. 6 Flow of the algorithm

## 4 结论

本文提出了一种基于卷积递归网络的电流互感器红外故障图像自动诊断方法。在平滑的基础上, 首先利用超像素分割方法将图像分割为多个内部性质近似的超像素区域, 利用超像素区域的颜色分布特性在 HSV 颜色空间分割出满足特征的故障区域并加以验证; 然后利用卷积递归神经网络识别得到的设备故障部位, 并依据故障部位得到对应的致热原因。从实验部分的精度分析和结果展示来看, 本文的算法具有较高的精度, 可适应性较强, 适用于不同变电设备类型的红外诊断。由于对红外图像的温度范围没有做进一步的识别, 仅仅对故障做了定性的分析, 下一步的工作将针对红外图像中数字标示的温度范围进行识别, 对诊断结果进行进一步的细化。

### 参考文献

- [1] 刘元锦. 变电站的运行与故障处理[M]. 北京: 中国水电出版社, 2004.
- [2] 马承志, 王宇雷, 杨玺, 等. 用于变电站自主巡视机器人的图像传输系统研究[J]. 电力系统保护与控制, 2014, 42(18): 105-109.
- [3] 史钦锋. 基于红外热像仪的变电站电力变压器过热故障在线监测[D]. 南京: 南京理工大学, 2009.
- [4] 王如意. 变电站电力设备红外图像分割技术研究[D]. 西安: 西安科技大学, 2011.
- [5] 叶婕. 基于图像分割的变电站电气设备故障自动检测[D]. 西安: 西安科技大学, 2012.
- [6] 解辰. 基于红外图像的电力变压器油位自动检测[D]. 西安: 西安理工大学, 2010.

- Xi'an University of Technology, 2010.
- [7] 梁利利. 变电站红外图像的识别与故障诊断[D]. 西安: 西安科技大学, 2010.  
LIANG Lili. Substation infrared image recognition and fault diagnosis[D]. Xi'an: Xi'an University of Science and Technology, 2010.
- [8] 魏钢, 冯中正, 唐跃, 等. 输变电设备红外故障诊断技术与试验研究[J]. 电气技术, 2013, 14(6): 75-78.  
WEI Gang, FENG Zhongzheng, TANG Yue, et al. The infrared diagnostic technology of power transmission devices and experimental study[J]. Electrical Engineering, 2013, 14(6): 75-78.
- [9] 金立军, 陈俊佑, 张文豪, 等. 基于图像处理技术的电力设备局部放电紫外成像检测[J]. 电力系统保护与控制, 2013, 41(8): 43-48.  
JIN Lijun, CHEN Junyou, ZHANG Wenhao, et al. Partial discharge detection of power equipment by ultraviolet imaging based on image processing technology[J]. Power System Protection and Control, 2013, 41(8): 43-48.
- [10] 熊军华, 贲超, 王亭岭. 基于多源信息融合的热缺陷监测系统研究[J]. 电力系统保护与控制, 2013, 41(5): 146-150.  
XIONG Junhua, YUN Chao, WANG Tingling. Research on monitoring system of thermal defects based on multi-source information fusion[J]. Power System Protection and Control, 2013, 41(5): 146-150.
- [11] LOWE, DAVID G. Object recognition from local scale-invariant features[C] // Proceedings of the International Conference on Computer Vision, 1999: 1150-1157.
- [12] BAY H, ESS A, TUYTELAARS T, et al. SURF: speeded up robust features[J]. Computer Vision and Image Understanding, 2008, 110(3): 346-359.
- [13] DALAL H N, TRIGGS B. Histograms of oriented gradients for human detection[C] // IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2005, 1: 886-893.
- [14] BENGIO Y. Learning deep architectures for AI[M]. Foundations and Trends in Machine Learning, 2009, 2(1): 1-56.
- [15] LEVINSHTEIN A, STEREA A, KUTULAKOS K, et al. Turbopixels: fast superpixels using geometric flows[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(12): 2290-2297.
- [16] OTSU N. A threshold selection method from gray-level histograms[J]. IEEE Transactions on Systems, Man and Cybernetics, 1979, 9(1): 62-66.
- [17] SOCHER R, HUVAL B, BHAT B, et al. Convolutional-recursive deep learning for 3D object classification[C] // Advances in Neural Information Processing Systems, 2012.
- [18] COATES A, NG A Y. Learning feature representations with K-means[C] // Neural Networks: Tricks of the Trade, Reloaded, Springer LNCS, 2012.
- [19] HINTON G E, OSINDERO S, TEH Y. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18: 1527-1554.
- [20] LEE H, EKANADHAM C, NG A Y. Sparse deep belief net model for visual area V2[C] // Advances in Neural Information Processing Systems, 2008.
- [21] COATES A, LEE H, NG A Y. An analysis of single-layer networks in unsupervised feature learning[C] // Artificial Intelligence and Statistics, 2011.

收稿日期: 2014-11-17; 修回日期: 2015-12-12

作者简介:

林颖(1986-), 女, 博士, 工程师, 当前研究方向为电力大数据、模式识别; E-mail: lysgwork@163.com

郭志红(1959-), 女, 教授, 高级工程师, 研究方向包括设备状态检修、电力大数据等相关方向;

陈玉峰(1970-), 男, 高级工程师, 主要从事高电压技术研究等专业技术和管理工作。

(编辑 周金梅)