

双监督信号深度学习的电气设备红外故障识别

贾 鑫^{1,2}, 张惊雷^{1,2*}, 温显斌³

(1. 天津市复杂系统控制理论及应用重点实验室, 天津 300384; 2. 天津理工大学 电气电子工程学院, 天津 300384; 3. 天津理工大学 计算机视觉与系统教育部重点实验室, 天津 300384)

摘要: 为提高电气设备红外故障图像识别准确率, 提出了基于双监督信号深度学习的电气设备红外故障图像识别方法。首先, 使用 Slic 超像素分割算法合并相似像素成区域块; 其次, 根据改进后 HSV 空间的亮度信息判别设备温度异常区域, 进而分割出温度异常区域所在的连通区域及所对应的设备; 最后, 基于 GoogLeNet 卷积神经网络对电气设备红外故障图像进行特征提取, 再采用 softmax 损失和中心损失两种监督信号对提取的特征进行监督训练, 并自行建立 700 幅电气设备红外故障图像数据集, 其中 500 幅用于训练, 200 幅用于测试。实验结果表明: 使用双监督信号深度学习算法测试准确率达到 98.6%, 比单独使用 softmax 损失时准确率提高了 1%。该算法能够对变压器套管、电流互感器、避雷器、隔离开关、绝缘子 5 种电气设备及其对应故障精准定位、识别。

关键词: 红外故障识别; softmax 损失; 中心损失; 卷积神经网络

中图分类号: TP391.4 **文献标志码:** A **DOI:** 10.3788/IRLA201847.0703003

Infrared faults recognition for electrical equipments based on dual supervision signals deep learning

Jia Xin^{1,2}, Zhang Jinglei^{1,2*}, Wen Xianbin³

(1. Tianjin Key Laboratory for Control Theory & Applications in Complicated System, Tianjin 300384, China;

2. School of Electrical and Electronic Engineering, Tianjin University of Technology, Tianjin 300384, China;

3. Key Laboratory of Computer Vision and System, Ministry of Education of China, Tianjin University of Technology, Tianjin 300384, China)

Abstract: In order to improve the accuracy of infrared fault image recognition for electrical equipment, an infrared fault image recognition method for electrical equipment based on double supervised signal deep learning was proposed. Firstly, a Slic super pixel segmentation algorithm was adopted to merge the similar pixel regions into blocks. According to the luminance information provided by the improved HSV space transformation, the temperature abnormal regions were determined. Secondly, the connected areas and the corresponding device of this region were separated. Finally, based on the GoogLeNet convolution neural network model, fault features of infrared images for electrical equipments were extracted, then trained and supervised by two kinds of signals, i.e., the softmax loss and the center loss signal. Among an established 700 infrared fault of electrical equipment images dataset, 500 of which are for training,

收稿日期: 2018-02-13; 修订日期: 2018-03-17

基金项目: 国家自然科学基金(61472278)

作者简介: 贾鑫(1993-), 男, 硕士生, 主要从事红外图像识别方面的研究。Email: 1026311742@qq.com

通讯作者: 张惊雷(1969-), 男, 教授, 硕士生导师, 博士, 主要从事模式识别、图像处理方面的研究。Email: zhangjinglei@tjut.edu.cn

and 200 for testing. Experiments results show that the test accuracy rate can reach to 98.6% which enhanced 1% when being compared with the classic method simply using the single softmax loss. The algorithm can accurately locate five kinds of electrical equipments which include the transformer bushing, current transformer, surge arrester, isolating switch, insulators, as well as identify the corresponding faults.

Key words: infrared fault recognition; softmax loss; center loss; convolution neural network

0 引言

根据统计资料,电气设备因接触不良、连接松动、漏磁、漏电而导致故障的情况超过半数以上。目前,传统电气设备巡检主要以人工识别为主,对工作人员依赖大,且危险度高。随着智能变电站和红外识别技术的发展,依靠计算机等辅助工具远程对设备热故障进行红外识别,可有效提高故障诊断效率,降低人身安全风险^[1]。

近年来,研究者相继提出了多种电气设备红外图像故障的识别方法。2013年,魏钢等人^[2]只对电气设备红外图像进行了基本的预处理,但依然要靠手工提取特征对故障的识别,所以不完全具备对于故障的自动识别能力;2016年,王佳林等^[3]使用 SOM 神经网络算法已经具备了自动诊断红外图像故障的雏形,但是算法较为简单,仅针对少量数据进行实验,当进行大数据分析时,运行速度慢,适应性较低。随着机器学习方法的发展,采用基于机器学习类算法进行红外故障识别成为技术热点。如 2016年,张迪飞等^[4]利用 HOG 算法对红外图像进行特征提取,然后基于训练的特征采用 SVM 进行分类。

近年来,模式识别领域最著名的方法是深度学习方法,在机器学习、海量图像处理及识别、图像理解中应用广泛。2016年,Ross Girshick 等^[5]提出了 ResNeXt 神经网络模型,该模型首次提出基数的概念,实现了一种多分支同构结构式衡量,发现增加基数比增加网络的深度、宽度更加有效,在 2016 年 ILSVRC 图像分类大赛中获得第二名。深度学习在电力系统中应用层出不穷,2017年,王万国等^[6]利用基于区域的卷积神经网络 (Regions Convolutional Neural Network, RCNN)对电气设备进行识别,结果表明采用深度学习算法可以实现电气设备的实时检测;刘兵等^[7]利用卷积神经网络对变压器局部放电信号图像进行识别,克服了传统机器学习算法人为计算

特征的缺陷,并能够准确评估变压器放电情况。

根据对电气设备红外故障图像的处理分析以及对深度学习算法的研究,文中以变压器套管,电流互感器,避雷器,隔离开关,绝缘子等 5 种电气设备为例进行电力系统设备故障自动识别研究。算法首先利用 Slic 超像素 HSV 空间变换算法排除无故障设备干扰,提取图像故障区域,以 GoogLeNet 模型为基础,使用 softmax 损失和中心损失两种监督信号对网络进行训练,使学习到的特征具有更好的泛化性,并准确识别出 5 种电气设备及其故障。文中方法可应用于历史红外故障图像和变电站红外故障图像、识别,提高供配电系统的稳定性,保障检修人员安全。

1 基于 Slic-HSV 算法的故障区域分割

文中为了提高识别精度,使用 Slic-HSV(超像素 HSV 空间变换)算法获取目标故障区域。虽然在故障区域的提取上消耗了一定的计算时间,但是,相应地减少了背景中无故障设备的干扰,反而提高了识别效率和精度。

1.1 Slic 算法

Slic 算法主要思想是将图像从 RGB 颜色空间转换到 CIE-lab 颜色空间,对应每个像素的 (l, a, b) 颜色值和 (x, y) 坐标组成一个 5 维向量 $[l, a, b, x, y]^T$,对于有 N 个像素的图像,将其分割成 K 个均匀大小的超像素集合,初始化聚类中心 $C_k = [l_k, a_k, b_k, x_k, y_k]^T$,每个聚类中心距离定义为 $s = \sqrt{N/K}$ 。通过计算每个像素点与距离最近的聚类中心之间的相似程度,使新的聚类中心更新到同类别中像素点 5 维向量平均值的位置,并不断迭代此过程,直到每个聚类中心不再发生变化为止,之后对该像素分配合理的标签。相似度的衡量关系如下:

$$d_{lab} = \sqrt{(l_k - l_i)^2 + (a_k - a_i)^2 + (b_k - b_i)^2} \quad (1)$$

$$d_{xy} = \sqrt{(x_k - x_i)^2 + (y_k - y_i)^2} \quad (2)$$

$$D(i,k)=d_{lab}+\frac{m}{s}d_{xy} \quad (3)$$

式中： d_{lab} 为颜色距离； d_{xy} 代表空间距离； s 为聚类中心的距离； $D(i,k)$ 为第 i 个像素点与第 k 个聚类中心的相似度^[8]。

1.2 基于 Slic-HSV(超像素 HSV 空间变换)算法的温度异常区域获取

针对图像红外信号分布特点，文中首先利用 Slic 超像素分割算法将同温度区域所对应的相似像素区域合并，然后采用改进的 HSV 空间变换提取设备故障点区域，进而扩散到整个设备区域，便于后续用深度学习算法进行设备及故障识别。

HSV 空间中 H、S、V，3 个通道分别代表图像的色度、饱和度、亮度。在红外图像中主要关注目标的亮度分量，即 H 的特征，不同的 H 值可以指代不同的颜色。电气设备温度异常故障区域特征在红外图像上主要表现为颜色偏黄或接近白色。黄色分量特点为 $R \approx G \geq B$ ，白色分量特点为 $R \approx G \approx B \approx 255$ ，据此可对 H 值计算公式做出以下修改：

$$\begin{cases} \text{if } (R>180\&G>180\&B>180) & H=360 \\ \text{if } (\max=B) & H=60\times\frac{R-G}{\max-\min} \\ \text{if } (\max=G) & H=60\times\frac{B-R}{\max-\min}+120 \\ \text{if } (\max=R) & H=60\times\frac{G-B}{\max-\min}+240 \end{cases} \quad (4)$$

式中： $R、G、B$ 分别为红外图像中每个像素的 $R、G、B$ ，3 个分量的灰度值。

Slic-HSV 算法流程图如图 1 所示。

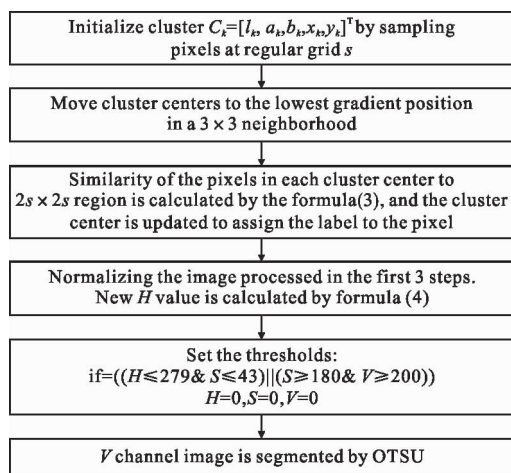


图 1 Slic-HSV 算法流程图

Fig.1 Procedure for Slic-HSV algorithm

1.3 故障设备区域分割

有些红外故障图像经分割完成后仅为一个或几个故障点，仅仅对一个温度异常区域进行分析无法有效获得故障类型和故障位置^[1]，因此需要分割出温度异常区域所对应的故障设备区域。在红外图像中的电气设备区域和背景区域有着明显区别。用 OTSU 算法可以分割出设备的二值图像，再使用数学形态学膨胀算法将孤立点连通，然后对故障区域进行标记。具体操作如下：

(1) 采用 OTSU (大津法) 对原图的灰度图像进行分割，得到二值图像 I_b ；

(2) 对故障点图像进行闭运算，连接二值图像中断开的区域和内部孔洞，标记区域为 R_s ；

(3) 计算二值图像 I_b 中所含故障区域的连通区域 R_0 ，计算方式为：寻找 I_b 的每个连通区域记为 j ， R_s 的每个连通区域记为 i ，判断： $\text{if } (i+j=1), R_0=R_{s(i)}+I_{b(j)}$ 。

2 基于双监督信号的深度学习算法

2.1 GoogLeNet 模型

2014 年 Christian Szegedy 等人设计 GoogLeNet 模型并获得同年 ILSVRC 冠军^[9]。GoogLeNet 模型的核心是 Inception 模块，主要思想是在卷积网络中逼近最优局部稀疏结构，模块个数为 9 个，Inception 模块如图 2 所示，模块彼此堆叠，每个权值对应一个乘法运算，在 $3 \times 3, 5 \times 5$ 卷积层前分别加上了起到降维作用的 1×1 的卷积核，可以减少参数数目，进行快速训练，提升精度。模型卷积过程使用一个可学习卷积层与上一层特征图做卷积运算，通过公式

$$h_j^k = f\left(\sum_{i \in M_j} h_i^{k-1} * w_{ij}^k + b_j^k\right)$$

可以得到相应特征， k 为层数，




图 2 Inception 模块结构图

Fig.2 Structure of Inception module

w 为卷积核; b 为偏置; M_j 为所输入特征图的集合; $f()$ 为非线性激活函数, 选用修正线性单元函数, 缓解过拟合现象。GoogLeNet 模型每层参数如表 1 所示。

表 1 GoogLeNet 模型参数
Tab.1 Parameters of GoogLeNet model

Type	Patch size/stride	Output size	Depth
Convolution	7×7/2	112×112×64	1
Max pool	3×3/2	56×56×64	0
Convolution	3×3/1	56×56×192	2
Max pool	3×3/2	28×28×192	0
Inception(3a)		28×28×256	2
Inception(3b)		28×28×480	2
Max pool	3×3/2	14×14×480	0
Inception(4a)		14×14×512	2
Inception(4b)		14×14×512	2
Inception(4c)		14×14×512	2
Inception(4d)		14×14×528	2
Inception(4e)		14×14×832	2
Max pool	3×3/2	7×7×832	0
Inception(5a)		7×7×832	2
Inception(5b)		7×7×1 024	2
Avg pool	7×7/2	1×1×1 024	0
Dropout		1×1×1 024	0
Linear		1×1×1 000	1
softmax		1×1×1 000	0

2.2 双监督信号深度学习算法结构

文中同时使用 softmax loss 和 center loss 两种监督信号在搭建好的 GoogLeNet 模型上进行训练, softmax loss 的作用是将多个神经元的输出映射到 (0,1) 区间内, 最小化分类概率和真实分布的交叉熵, 使分类的概率接近更加接近真实类别。添加 center loss 目的是在配合 softmax loss 使用的时候通过惩罚每个种类的样本和该种类样本中心的偏移, 让处于同一类别的样本能都靠近对应类别的特征中心, 进而使网络容易训练和优化。模型在不同深度处的两个辅助 softmax loss 旨在用于避免梯度回传消失现象。因此只在最后的 softmax loss 基础上加入 center loss。文中算法整体架构如图 3 所示。

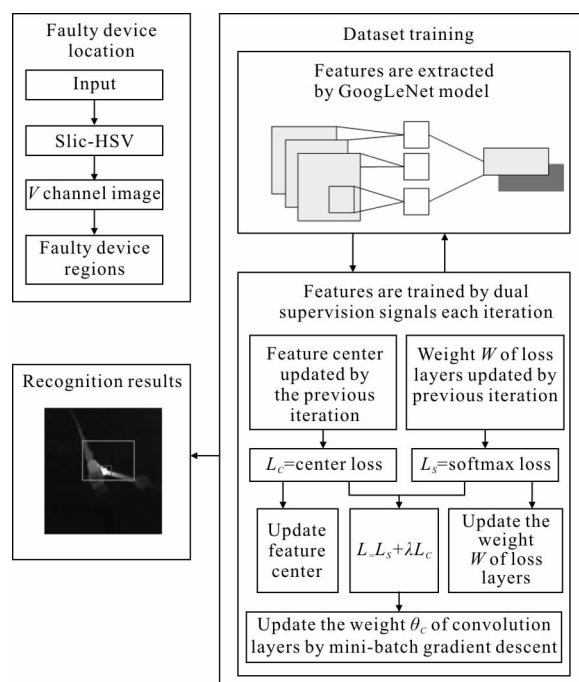


图 3 算法整体构架

Fig.3 Framework of algorithm

定义 softmax loss 函数为:

$$L_s = - \sum_{i=1}^m \log \frac{e^{W_{y_i}^T x_i + b_{y_i}}}{\sum_{j=1}^n e^{W_j^T x_i + b_j}} \quad (5)$$

式中: x_i 表示属于第 y_i 类别的第 i 个样本特征; W_j 表示全连接层的参数矩阵的第 j 列; b 表示偏置。

定义 center loss 函数为:

$$L_c = \frac{1}{2} \sum_{i=1}^m \|x_i - c_{y_i}\|_2^2 \quad (6)$$

式中: c_{y_i} 为属于第 y_i 类特征中心。

文中通过 MBGD(小批量梯度下法)更新卷积层的权重 θ_c 并且做了两个必要工作使得特征中心根据该分类特征的平均值进行更新:(1) 在每次更新特征中心时, 使用小批量处理的方式更新对应类别的特征中心, 公式(5)、(6)、(9)中 m 为每一次迭代时小批量处理的样本数目;(2) 为避免一些错误的样本引起扰动, 所以用控制特征中心的学习率($\alpha=0.5$)。

每一次迭代计算当前样本特征和特征中心的距离, 然后把把这个距离以梯度的形式叠加到特征中心上。

$$C_j^{t+1} = C_j^t - \alpha \Delta C_j^t \quad (7)$$

$$\frac{\partial L_c}{\partial x_i} = x_i - c_{y_i} \quad (8)$$

$$\Delta c_j = \frac{\sum_{i=1}^m \delta(y_i=j)(c_j - x_i)}{1 + \sum_{i=1}^m \delta(y_i=j)} \quad (9)$$

式中： $\delta(y_i=j)$ 为指示函数，当 $y_i=j$ 时指示函数为 1，否则为 0。这样做满足了特征中心的更新方式。

为了平衡两个损失函数之间的比例加入超参数 λ ，最终 loss 函数为：

$$L=L_s+\lambda L_c=-\sum_{i=1}^m \log \frac{e^{W_i^T x_i+b_i}}{\sum_{j=1}^n e^{W_j^T x_i+b_j}}+\lambda \frac{1}{2} \sum_{i=1}^m \|x_i-c_{y_i}\|_2^2 \quad (10)$$

使用 softmax loss 与 center loss 联合监督训练步骤如表 2 所示。

表 2 softmax loss 与 center loss 联合监督训练步骤

Tab.2 softmax loss and center loss joint supervision training steps

softmax loss and center loss joint supervision training steps
Input : training data $\{x_i\}$. Initialized weight θ_c in convolution layers. Weight W and $\{c_j j=1,2, \dots,n\}$ in loss layers.Hyperparameter λ, α and learning rate μ' . The number of iteration $t \leftarrow 0$
Output : weight θ_c
While not converge do $t \leftarrow t+1$
Compute the joint loss: $L' = L'_s + \lambda L'_c$
Compute the backpropagation error for each i : $\frac{\partial L'_i}{\partial x_i} = \frac{\partial L'_s}{\partial x_i} + \lambda \frac{\partial L'_c}{\partial x_i}$
Update the weight W : $W^{t+1} = W^t - \mu' \frac{\partial L'_s}{\partial W^t}$
Update feature center for each j : $C_j^{t+1} = C_j^t - \alpha \Delta C_j^t$
Update the weight θ_c : $\theta_c^{t+1} = \theta_c^t - \mu' \sum_i \frac{\partial L'_i}{\partial x_i} \frac{\partial x_i}{\partial \theta_c}$
End while

3 实验结果分析

文中选用自行建立的电气设备红外故障图像数据集共 700 幅图片，共分为 10 种设备：变压器套管、电流互感器、绝缘子、避雷器、隔离开关、变压器、断路器、输电线路、架空线路导线、变压器冷却器。以 500 幅图片作为训练集，200 幅图片为测试集。对其中变压器套管、电流互感器、绝缘子、避雷器、隔离开关 5 种电气设备及其热故障进行分类。实验计算机配置为 Intel Core i5-5200U, 2.20 GHz，内存 4G，显卡 AMD Radeon R7 M260，操作系统为 64 位

Windows7，使用 caffe 深度学习框架，编程环境为 Matlab R2014a, Python2.7。

3.1 识别算法精度分析

根据实验设备硬件条件对改进网络结构的参数取值进行合理设置，将网络结构中训练集批处理尺寸(batch_size) m 设定为 72。文中取 500 幅图片进行训练, 200 幅图片进行测试, 根据测试集中批处理尺寸(batch_size) \times 测试时迭代次数(test_iter)=测试集数量的原则，测试集中 batch_size 取值为 10，test_iter 取值为 20。学习率 μ 设置为 0.001，迭代次数为 1 500 次。center loss 中的超参数 λ 设置为 0.003。

文中为改进后 CNN 模型取名 improve_cnn，改进后 CNN 模型训练出的中心损失曲线如图 4 所示。实验使用不同深度学习模型对电气设备红外故障图像数据集进行训练和测试。不同 CNN 模型训练出的最终损失曲线如图 5 所示。

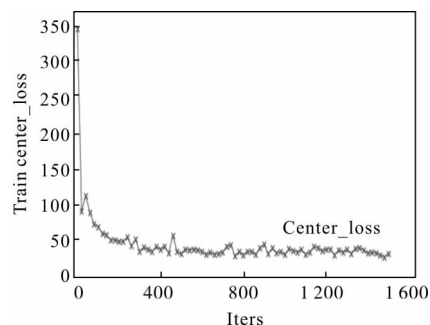


图 4 改进后 CNN 模型的中心损失

Fig.4 Center loss of improved CNN model




图 5 不同 CNN 模型损失效果

Fig.5 Loss effect of different CNN models

在训练网络时设置每 500 次迭代进行一次准确率测试，并绘制 4 种不同算法准确率如图 6 所示，可以看出使用双监督信号训练出的网络虽然损失比原

网络有小幅增长,识别准确率却比原模型要高 1% 左右,可以达到 98.6%。

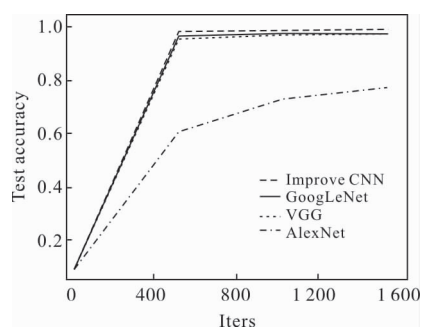


图 6 不同 CNN 模型准确率

Fig.6 Accuracy of different CNN models

使用 4 种不同 CNN 模型分别对 5 种电气设备故障进行识别,每种算法使用统一识别流程为:故障目标获取—特征提取—分类识别。将电流互感器接头发热,隔离开关转头发热,变压器套管柱头发热,合成绝缘子球头发热,避雷器整体发热 5 种故障分别命名为 S1~S5。对 5 种不同电气设备故障识别率如表 3 所示。

表 3 电气设备故障识别率

Tab.3 Fault identification of power equipment

CNN model	S1	S2	S3	S4	S5
AlexNet	82.1%	79.4%	82.5%	81.6%	78.8%
VGG	95.6%	93.7%	94.3%	95.2%	92.4%
GoogLeNet	96.2%	97.4%	95.1%	94.8%	96.6%
Model	97.1%	98.1%	98.1%	95.2%	97.3%

3.2 识别结果分析

文中选取了 6 幅不同类型的红外故障图像为例来说明算法流程,如图 7 所示。图 7 的横向行为实际故障设备分别为:(1)隔离开关;(2)电流互感器、合成绝缘子;(3)变压器套管;(4)避雷器;(5)电流互感器;(6)合成绝缘子。图 7 的纵向列分别为算法步骤,其中图(a)列为故障设备的红外图像,图(b)列为 Slic 超像素分割结果,图(c)列为 Slic-HSV 算法后得到的温度异常区域图像,图(d)列为识别出的故障设备区域及故障结论。可见,在故障定位阶段,文中算法能有效收敛到故障设备区域;在识别阶段,使用双信号监督深度学习算法对设备及其故障进行识别,并根据 DLT664-2008 带电设备红外诊断应用规范,给

出故障结论。从实验结果来看,该算法适用于不同类型电气设备的热故障的诊断。

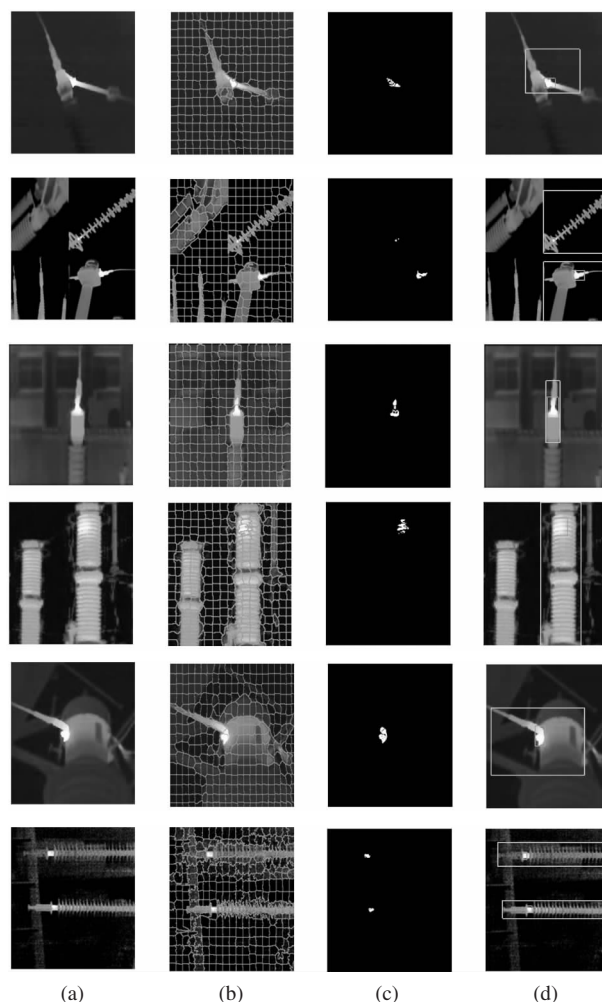


图 7 电气设备故障识别结果

Fig.7 Fault recognition results of electrical equipment

根据 DLT664-2008 带电设备红外诊断应用规范,图 7 所示设备,按设备名称、发热部位、热像特征、故障结论等识别如下:

(1) 隔离开关。发热部位:转头;热像特征:以转头为中心的热像;故障结论:转头接触不良或断股。

(2) 电流互感器。发热部位:接头;热像特征:以串并联或大螺栓出线夹为最高温度的热像或顶帽发热为特征;故障结论:螺旋杆接触不良;合成绝缘子;发热部位:球头;热像特征:球头部位过热;故障结论:球头部位松脱、进水。

(3) 变压器套管。发热部位:柱头;热像特征:以套管顶部柱头为最热的热像;故障结论:柱头内部并线压接不良。

(4) 避雷器。发热部位:整体;热像特征:较热点靠上部,由上到下温度递减;故障结论:阀片受潮或老化。

(5) 电流互感器。发热部位:接头;热像特征:以串并联或大螺栓出线夹为最高温度的热像或顶帽发热为特征;故障结论:螺旋杆接触不良。

(6) 合成绝缘子。发热部位:球头;热像特征:球头部位过热;故障结论:球头部位松脱、进水。

4 结 论

文中通过分析深度学习算法和红外图像特性提出了一种基于双监督信号深度学习的电气设备红外图像故障识别方法,使用 center loss 与 softmax loss 两种监督信号对自行建立的电气设备红外故障图像数据集进行训练,训练方法为有监督训练,虽然已达到较高准确率,但数据集规模仍然对最后的识别率有着很大程度的影响,下一步工作将对数据集进行完善,增加学习样本数量,减少识别错误率。文中算法在具有足够数据量的情况下,可针对所有电气设备红外故障图像进行故障识别,灵活性高,鲁棒性强。

参考文献:

- [1] Lin Ying, Guo Zhihong, Chen Yufeng. Conv olutional – recursive network based current transformer infrared fault image diagnosis [J]. *Power System Protection and Control*, 2015, 43(16): 87–94. (in Chinese)
- [2] 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. (in Chinese)
- [3] Wang Jialin, Cui Haoyang, Xu Yong, et al. Infrared image diagnosis method of transformer substation equipment base on SOM neural network[J]. *Journal of Shanghai University of Electric Power*, 2016, 32(1): 78–82. (in Chinese)
- [4] Zhang Difei, Zhang Jinsuo, Yao Keming, et al. Infrared ship –target recognition based on SVM classification [J]. *Infrared and Laser Engineering*, 2016, 45(1): 0104001. (in Chinese)
- [5] Xie Saining, Ross Girshick, Piotr Dollár, et al. Aggregated residual transformations for deep neural networks [C]//IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1492–1500.
- [6] Wang Wanguo, Tian Bing, Liu Yue, et al. Study on the electrical devices detection in UAV images based on region based convolutional neural networks [J]. *Journal of Geo – Information Science*, 2017, 19(2): 256–263. (in Chinese)
- [7] Liu Bin, Zhang Jian. Partial discharge recogniton in power transformers based on convolutional neural networks [J]. *High Voltage Apparatus*, 2017, 53(5): 70–74. (in Chinese)
- [8] Wang Juan, Wang Ping, Wang Gang. Stippled direct part mark location based on self –adaptive super –pixels segmentation[J]. *Acta Automatica Sinica*, 2015, 41(5): 991–1003. (in Chinese)
- [9] Liu Wei, Christian Szegedy, Jia Yangqing, et al. Going deeper with convolutions[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1–9.
- [10] Wen Yandong, Zhang Kaipeng, Li Zhifeng, et al. A discriminative feature learning approach for deep face recognition [C]//European Conference on Computer Vision, 2016: 499–515.