

DOI: 10.13382/j.jemi.B2002978

# 基于改进胶囊网络的电力线巡线异物检测\*

宋立业 王诗翱 刘昕明

(辽宁工程技术大学 电气与控制工程学院 葫芦岛 125000)

**摘要:**针对电力线巡线异物检测使用的传统卷积神经网络空间辨识度较差、训练样本需求过多的问题,提出一种改进胶囊网络模型。使用数据灰度化、三维块匹配滤波算法预处理巡线数据集。提出自适应贡献池化降低数据信息丢失量,异物数据深度信息提取单元提取主要特征来滤除冗余信息、减少数据数量以改善模型性能,改进异物识别主胶囊层和动态路由结构以适应电力线巡线异物检测的二分类情况。对自适应贡献池化和最大池化,无池化、传统结构胶囊网络和改进胶囊网络,改进胶囊网络和 AlexNet、GoogLeNet 分别进行异物识别对比实验和改进胶囊网络的空间辨识度性能进行测试实验。实验结果表明,在 3 700 张小训练样本条件下,经 20 次训练后,自适应贡献池化比最大池化的改进胶囊网络平均准确率提高 2.7%,改进胶囊网络比无池化、传统结构胶囊网络平均准确率提高 3.6%,改进胶囊网络比 AlexNet、GoogLeNet 的平均准确率分别提高 21.9%和 12.6%,且改进胶囊网络在大小、角度不同的测试数据中仍具有高于 91%的平均准确率。改进胶囊网络在空间辨识度复杂、少训练样本情况下仍具有较高的异物识别能力,实现了高效率、高准确率的自动化无人巡线异物检测。

**关键词:** 电力线巡线;异物识别;空间辨识度;小训练样本;自适应贡献池化;改进胶囊网络

**中图分类号:** TM761

**文献标识码:** A

**国家标准学科分类代码:** 470

## Detection of foreign objects in power line patrol based on improved capsule network

Song Liye Wang Shiao Liu Xinming

(Faculty of Electrical and Control Engineering, Liaoning Technical University, Huludao 125000, China)

**Abstract:** Aiming at the problems of poor spatial recognition and excessive training sample requirements of traditional convolutional neural networks used in power line patrol foreign object detection, an improved capsule network model is proposed. The gray-scale data and three-dimensional block matching filter algorithm are used to preprocess the line survey data set. The adaptive contribution pooling is proposed to reduce the amount of data information loss. The foreign object data depth information extraction unit extracts the main features to filter out redundant information, reduce the number of data to improve model performance, improve the foreign object recognition of main capsule layer and dynamic routing structure to adapt to power line patrol for the second classification of line foreign object detection. For adaptive contribution pooling and maximum pooling, non-pooling, traditional structure capsule network and improved capsule network, improved capsule network and AlexNet, GoogLeNet were respectively compared with foreign object recognition experiment and improved capsule network spatial recognition performance. The experimental results show that under 3 700 small training samples, after 20 trainings, the average accuracy of the improved contribution network of adaptive contribution pooling is greater than the maximum pooling by 2.7%, and the improved capsule network is better than the non-pooling, traditional structure capsules. The average accuracy of the network is increased by 3.6%, and the improved accuracy of the improved capsule network is 21.9% and 12.6% higher than that of AlexNet and GoogLeNet, respectively, and the improved capsule network still has an average accuracy higher than 91% in test data of different sizes and angles. The improved capsule network has high foreign object recognition ability under the condition of complicated spatial recognition and few training samples, and realizes high-efficiency and high-accuracy automatic unmanned line inspection foreign object detection.

**Keywords:** power line inspection; foreign object recognition; spatial recognition; small training samples; adaptive contribution pooling; improved capsule network

收稿日期:2020-02-26 Received Date: 2020-02-26

\* 基金项目:辽宁省重点研发指导计划(2019JH8/10100050)、辽宁省教育厅科学研究一般项目(LJYL013)资助

## 0 引言

架空电力线是电力系统的重要组成部分,其安全稳定的运行是我国人民正常生活、生产的重要前提条件<sup>[1]</sup>。影响电力线正常运行的主要有人为破坏、环境因素、外来异物影响几种因素。其中最突出的问题是外来异物对电力线正常运行的干扰<sup>[2]</sup>。近年来对于电力线异物,国内外大量采用无人机巡线<sup>[3]</sup>,机器人巡线<sup>[4]</sup>等无人化方式采集电力线巡线图像数据,再通过算法对已获得的数据集进行分类,来自动检测电力线是否存在异物。

对于电力线异物检测研究最初使用传统图像处理方法对异物图像进行特征分析。文献[5]使用 K-L-T 算法进行图像特征匹配。文献[6]使用竖直与水平检测算子来完成复杂背景下的异物检测。文献[7]通过改进 Otsu 算法,使用 Hough 变换计算极值点,消除异物图像背景,来完成电力线异物检测。

随着深度学习的逐步发展,卷积神经网络模型应用在图像数据集分类之中。文献[8]使用 dropout 机制和 ReLU 激活单元改进了 LeNet-5 的整体结构以减缓过拟合。谷歌使用 GoogLeNet<sup>[9]</sup>并提出 Inception 模块来解决由于训练数据集样本过少导致的模型过拟合。

传统卷积神经网络的训练需要大量的异物、非异物数据集。电力线异物图像数据获取难度大,若用数量不足的训练数据集会导致传统卷积神经网络模型过拟合。并且传统卷积神经网络对异物空间辨识度较差,若获取数据时由拍摄角度造成异物大幅度旋转、翻转,模型检测异物能力会大幅下降。针对传统卷积神经网络应用于数据分类的问题,Hinton 等<sup>[10]</sup>提出转换自动编码器来产生特征位置的显式矢量来代替传统卷积神经网络产生的特征检测标量,有效的克服了空间辨识度较差的问题。文献[11]通过胶囊网络中的活动矢量来代表特定类型的实例化参数,使用动态路由算法代替反向传播过程,改进了模型的整体结构,提升了整体平均识别准确率和模型收敛速度。

本文通过改进胶囊网络结构用以适应无人机巡线在不同拍摄角度、不同拍摄环境,数据集为小样本情况下的电力线异物识别。有效解决了上述算法空间辨识度较差、训练样本需求过多的问题。同时提高了电力线异物巡检的平均准确率,并使无人机采集的不同外部环境下的数据集都可在改进胶囊网络结构中使用,提高了无人机采集数据的使用效率。实现了高效率的自动化无人巡线异物检测。

## 1 数据集获取与预处理

由于电力线上一旦存在异物,工作人员会及时清理,

因此电力线异物数据集获取的难度较大。本文采用网络爬虫进行爬取、谷歌深度学习数据库、无人机现场拍摄三种方式获取,共获取 1 200 张异物数据图像,2 500 张正常数据图像。

对于传统卷积神经网络而言,数量不多的数据集非常容易造成整体模型的过拟合,鲁棒性不强。但胶囊网络使用矢量数据代替标量数据表示特征的空间关系,所以并不需要大量的数据集就可以完成模型的训练过程。

获取的数据集为 RGB 三通道,但异物检测只需检测异物的存在性,颜色特征并不是检测的关键,所以将原始数据集进行灰度化,利用三维块匹配滤波 BM3D 算法进行数据集去噪,并将其大小调整为 112×112×1 以适应改进胶囊网络的输入,部分预处理后的数据集如图 1 所示。




图 1 部分预处理后的数据集

Fig. 1 Partially preprocessed dataset

## 2 用于电力线巡线异物检测的胶囊网络

### 2.1 自适应贡献池化层

对于识别电力线异物的模型而言,大部分使用最大池化来进行特征降维、压缩数据、减少参数数量<sup>[12]</sup>。池化层会不断地减小数据的数量大小,因此参数的数量和总体计算量会大量下降,虽然在一定程度上控制了过拟合,但这将会减少大部分的数据信息量,最终保留的数据信息量仅为小部分。其最大的问题是针对电力线异物图像在进行池化操作的时候会只选择区域内的最大像素值,其余的非最大像素值全部被抛弃,导致数据点丢失。同时现阶段的识别电力线异物的模型训练时,池化区域的大小、迭代次数的选择都为启发式试错调参。当每次改变池化区域的大小、迭代次数时,如果池化算法不能随之自适应,则会影响最后的识别结果,导致平均识别准确率较低。

因此本文提出一种改进的池化方式以改进上述问题,称为自适应贡献池化。自适应贡献池化的计算方法如下:

$$Pvalue = \alpha \sum_{i=1}^s \sum_{j=1}^s \left[ \frac{(F_{ij})^2}{\sum_{i=1, j=1}^s (F_{ij})} \right] \quad (1)$$

式中： $\alpha$  为自适应贡献池化因子； $s$  为池化区步长； $F_{ij}$  为卷积层输出（自适应贡献池化层输入）； $Pvalue$  为自适应贡献池化层输出。

$$\alpha = \delta \left\{ \frac{\sum_{i=1, j=1}^s (F_{ij})}{s^2 \max_{i=1, j=1} (F_{ij})} - \left[ \frac{\sum_{i=1, j=1}^s (F_{ij})}{s^2 \max_{i=1, j=1} (F_{ij})} \right]^2 \right\} \quad (2)$$

式中： $\delta$  为自适应调节因子； $s$  为池化区步长； $F_{ij}$  为卷积层输出。

$$\delta = \frac{1 + s}{1 + (m - 1)s^{m^2 - 1}} \quad (3)$$

式中： $s$  为自适应贡献池化步长； $m$  为迭代次数。

由式(1)~(3)可知，自适应贡献池化因子和卷积层输出共同决定自适应贡献池化层输出。其中自适应贡献池化因子根据插值原理由自适应调节因子和卷积层输出共同决定。自适应调节因子由当前自适应贡献池化步长和迭代次数决定。通过每次训练时设定的池化区域的大小、迭代次数来自适应的调节公式(式(1))中的自适应贡献池化因子以提高最终识别平均准确率<sup>[13]</sup>。

### 2.2 电力线异物深度特征提取单元

胶囊网络最初在手写数字数据集中应用，其分类目标为十分类<sup>[14]</sup>。为适合电力线异物巡线检测二分类的研究，将胶囊网络输入改变为  $112 \times 112 \times 1$  的灰度数据，并增加深度特征提取单元，深度特征提取单元如图 2 所示。




图 2 电力线异物深度特征提取单元示意图

Fig. 2 Schematic diagram of power line foreign body depth feature extraction unit

由图 2 可知， $112 \times 112 \times 1$  的数据首先通过 128 个  $3 \times 3$  大小步长为 1 的卷积核得到 128 个  $112 \times 112$  的特征图，其次通过一个  $2 \times 2$  大小步长为 1 的自适应贡献池化层得到 128 个  $56 \times 56$  的特征图，再通过 256 个  $3 \times 3$  大小步长为 1 的卷积核得到 256 个  $56 \times 56$  的特征图，最后通过一个  $2 \times 2$  大小步长为 1 的自适应贡献池化层得到 256 个  $28 \times 28$  的深度特征提取单元输出。其中卷积层的激活函数使用 ReLU<sup>[15]</sup>。

### 2.3 改进电力线异物识别主胶囊层

将电力线异物深度特征提取单元的输出首先通过 8 组每组 32 个  $3 \times 3$  大小步长为 1 的卷积核，得到 8 组每组 32 个  $26 \times 26$  大小的特征图，其次通过一个自适应贡献池化层得到 8 组每组 32 个  $13 \times 13$  的特征图，最后将池化结果拉平然后对对应位置组合得到 5 408 个胶囊。每个胶囊中都是  $1 \times 8$  的向量。改进主胶囊层示意图如图 3 所示。




图 3 改进电力线异物识别主胶囊层示意图

Fig. 3 Schematic diagram of improved main capsule layer for power line foreign object recognition

由图 3 可知，加入自适应贡献池化可使异物数据集变为  $13 \times 13$ ，实现电力线异物深度特征数据压缩。通过保留的主要特征信息减少数据量和训练参数，加快模型训练过程。

### 2.4 改进动态路由异物识别结构

由于电力线巡线异物检测最终结果是二分类，所以将主胶囊层产生的 5 408 个胶囊通过图 4 所示的方式进行动态路由来更新参数。




图 4 改进的动态路由结构

Fig. 4 Improved dynamic routing structure

由图 4 可知，主胶囊层的输出通过全连接的方式连接到动态路由单元，共有  $5 408 \times 2$  个权重，每个权重均为  $8 \times 16$  的向量。动态路由单元共有两层，其中每一层共 5 408 个计算因子相当于一个高层特征并分别对应最终二分类结果。

在动态路由中， $u + 1$  层胶囊由  $u$  层胶囊计算得出。在动态路由的最初阶段  $u + 1$  层胶囊和  $u$  层胶囊可认为

是全连接,  $u$  层胶囊连接到  $u + 1$  层胶囊的概率如下:

$$c_{ij} = \frac{\exp(b_{ij})}{\sum_j (b_{ij})} \quad (4)$$

式中:  $b_{ij}$  是胶囊  $i$  连接到胶囊  $j$  的先验概率, 其值初始化为 0。

$u$  的最终层 ( $v$  层) 的输出胶囊输出如下:

$$u(v_j) = \frac{\|s_j\|^2}{1 + \|s_j\|^2} \frac{s_j}{\|s_j\|} \quad (5)$$

式中:  $u(v_j)$  为  $u + 1$  层胶囊  $j$  的输出;  $s_j$  为  $u(v_j)$  层胶囊的总输入。

在路由更新环节, 通过迭代训练两层中胶囊  $i$  和  $j$  的连接概率  $c_{ij}$ 。首先计算  $u$  层胶囊  $i$  对  $u + 1$  层胶囊  $j$  的输出预测, 将  $u$  层所有胶囊与其对应的连接概率的乘积求和作为  $u$  层对  $u + 1$  层胶囊  $j$  的输入, 公式如下:

$$\hat{s}_j = \sum_i c_{ij} \hat{u}_{ji}, \hat{u}_{ji} = \mathbf{W}_{ij} u_i \quad (6)$$

式中:  $\hat{u}_{ji}$  为预测结果;  $\mathbf{W}_{ij}$  为路由矩阵。最后将预测结果和  $u + 1$  层输出向量共同更新  $b_{ij}$ , 从而更新权重  $c_{ij}$ , 更新过程如下:

$$b_{ij} \leftarrow b_{ij} + \hat{u}_{ji} \cdot v_j \quad (7)$$

### 3 实验结果

将部分  $112 \times 112 \times 1$  的电力线异物图像输入训练好的改进胶囊网络模型并可视化模型的卷积结果。单个数据的深度特征提取单元输出结果如图 5 所示。




图 5 单个数据的深度特征提取单元输出结果

Fig. 5 Output result of deep feature extraction unit of single data

图 5 对应图 2 中最后一个自适应贡献池化层的第 3 维度——共 256 个卷积核, 256 个卷积核对应着  $16 \times 16$  个共 256 个图像。

由图 5 可知, 输入进深度特征提取单元的图像与卷积核进行卷积运算。经过 256 个卷积核后图像的分辨率变小, 图像的内容越来越抽象, 更加注重提取电力线异物的整体轮廓与形状, 可以有效剔除冗余信息, 将有效信息提纯。

将图 5 的深度特征提取单元输出的 256 个特征图按照 1:1 的比例进行融合, 可以得到深度特征提取之后的输出结果, 部分数据融合结果如图 6 所示。

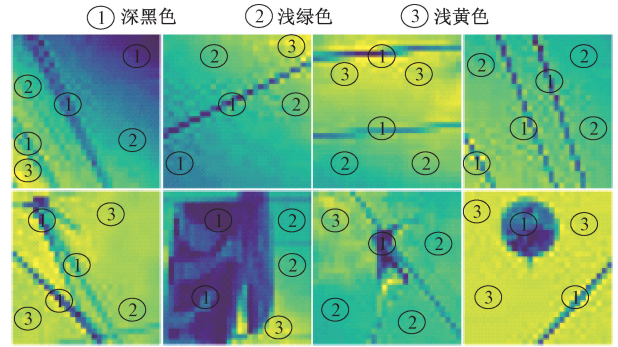


图 6 部分数据融合结果

Fig. 6 Partial data fusion results

图 6 为部分异物图像原始数据经过深度特征提取单元后的 256 个卷积核图像融合为单张图像结果。为了方便可视化, 将异物主体和电力线部分设置为负向量, 背景和其他信息设置为 0 或正向量。其中负向量由深黑色表示, 零或正向量用浅黄色和浅绿色表示。数据融合结果图清晰地展示了异物图像中异物的形状、轮廓、内部层次等特征, 非异物图像中仅有电力线的图像特征。滤除了背景信息、冗余信息, 降低了数据数量, 使后续分析识别更加容易。

将部分数据融合结果输入数据主胶囊层中, 部分数据主胶囊层结果如图 7 所示。

由图 7 可知, 胶囊层将输入图像变为 5 408 个向量, 进入主胶囊层后的数据仅改变向量的长度, 而不改变角度, 可以使向量在 0~1, 避免了过大的数据量对模型性能的干扰。但其空间表征为抽象表征, 并不能看出胶囊层向量的实际数据含义, 即无法通过主胶囊层可视化的识别异物图像有何区别, 但将其结果送入数字胶囊层可实现异物图像的识别。

将图 7 的主胶囊层输出向量输入进数字胶囊层, 并由动态路由结构实现最终的异物图像分类功能, 部分数据数字胶囊层结果如图 8 所示, 其中每个胶囊都是 16 维度的向量。

由图 8 可知, 数字胶囊层得到两个 16 维向量。向量的维度代表着数据分类的置信度, 向量的数量代表着分类的结果。由于组中结果为二分类——异物与非异物, 因此每个数据图像均对应着两个向量模块。非异物数据




图 7 部分数据主胶囊层结果

Fig. 7 Partial data main capsule layer results




图 8 部分数据数字胶囊层结果

Fig. 8 Digital capsule layer results for partial data

的第 1 个向量被激活,异物数据的第 2 个向量被激活,被激活的向量通过黑白灰度化可视表征。第 1 个向量越偏向于黑色越代表异物存在的概率越大,第 2 个向量越偏向于黑色越代表非异物存在的概率越大。图 8 第 1 行非异物图像的第 1 个向量结果偏向于白色,第 2 个向量结果偏向于黑色,代表了非异物分类。图 8 第 2 行异物图像的第 1 个向量结果偏向于黑色,第 2 个向量结果偏向于白色,代表了异物分类。

该向量还可以用于生成输入图像的重建以测试模型对空间辨识度的识别效果,输入图像的重建结果如图 9 所示。

由图 9 可知,其第 1 行代表调节对应向量时异物右侧特征的大小,其第 2 行代表调节对应向量时异物左侧特征的大小,其第 3 行代表调节对应向量时异物空间角度特征的变化,其第 4 行代表调节对应向量时异物下册特征的大小。通过对数字胶囊层向量不同维度的大小调节可观察到模型对空间辨识度的识别效果良好。无论异物处于何种大小、方向,模型数据变化的只是向量的变化,而不影响最终的识别效果。



图 9 数字胶囊层重建结果

Fig. 9 Digital capsule layer reconstruction results

### 3.1 实验设置

#### 1) 实验环境

本实验程序运行在单台 8 核 16 线程 Corei7,32G 内存的服务器台式机,使用定制大疆巡线无人机进行数据采集。数据集预处理在 MATLAB 完成,模型搭建与训练程序均采用 TensorFlow 框架并使用 Python3.7 运行。

#### 2) 实验数据集

将获取的 1 200 张异物数据图像,2 500 张正常数据图像,共 3 700 张图像按照训练样本和测试样本 4 : 1 的比例进行划分。其中 960 张异物数据,2 000 张正常数据进行模型训练,240 张异物数据,500 张正常数据进行模型测试。

#### 3) 实验参数设置

共进行 50 次迭代,首次迭代进行 20 张数据的训练,后 49 次迭代进行每次 60 张数据的训练,路由迭代次数设置为 3,反向传播学习率设置为 0.001。

### 3.2 对比最大池化与自适应贡献池化实验

将深度特征提取单元与主胶囊中的池化层分别配置为传统最大池化层与改进自适应贡献池化层,共训练 20 次,其平均准确率、平均训练时长如表 1 所示。

表 1 最大池化与自适应贡献池化平均准确率、平均训练时长表

Table 1 Maximum pooling and adaptive contribution pooling average accuracy rate, average training time table			
模型种类	池化类型	平均准确率/%	平均训练时长/s
改进胶囊网络	最大池化	95.6	1 355
改进胶囊网络	自适应贡献池化	98.3	2 567

由表 1 可知,最大池化的平均训练时长为 1 355 s,自适应贡献池化的平均训练时长为 2 567 s。虽然自适应贡献池化的训练时长相比最大池化略长,但配置自适应贡献池化的胶囊网络平均准确率为 98.3%,配置最大池化

的平均准确率为 95.6%。提出的自适应贡献池化方式可减少数据信息量的丢失,并使卷积神经网络在不同的池化区域、不同的迭代次数下均可以精准的提取数据信息特征<sup>[13]</sup>。

### 3.3 对比传统胶囊网络与改进胶囊网络实验

使用传统胶囊网络与改进胶囊网络模型分别训练 20 次,其平均准确率、平均训练时长如表 2 所示。

表 2 传统胶囊网络与改进胶囊网络平均准确率、平均训练时长表

Table 2 Traditional capsule network and improved capsule network average accuracy rate, average training time

模型种类	池化类型	平均准确率/%	平均训练时长/s
胶囊网络	无池化	94.5	1 086
改进胶囊网络	自适应贡献池化	98.1	2 769

由表 2 可知,传统胶囊网络的平均训练时长为 1 086 s,改进胶囊网络的平均训练时长为 2 769 s。传统胶囊网络平均准确率为 94.5%,改进胶囊网络的平均准确率为 98.1%。

实验证明改进胶囊网络可以提取更深层次的特征,并使用最大池化改善数据信息丢失问题,使平均准确率得以提升

### 3.4 对比 AlexNet, GoogLeNet, 改进胶囊网络实验

使用 AlexNet、GoogLeNet、改进胶囊网络分别训练 20 次,其平均准确率、平均训练时长如表 3 所示。

表 3 改进胶囊网络与 AlexNet、GoogLeNet 平均准确率、平均训练时长表

Table 3 Improve the average accuracy of the capsule network, AlexNet and GoogLeNet, and the average training time

模型种类	池化类型	平均准确率/%	平均训练时长/s
AlexNet	最大池化	76.3	1 287
GoogLeNet	最大池化	85.6	7 869
改进胶囊网络	自适应贡献池化	98.2	2 677

由表 3 可知, AlexNet 的平均训练时长为 1 287 s,改进胶囊网络的平均训练时长为 2 677 s。GoogLeNet 的平均训练时长为 7 869 s。AlexNet 的平均准确率为 76.3%,改进胶囊网络的平均准确率为 98.2%。GoogLeNet 的平均准确率为 85.6%。由于改进胶囊网络结构复杂于 AlexNet 又设置自适应贡献池化层,但相比于 GoogLeNet 结构较为简洁,因此改进胶囊网络的平均训练时长高于 AlexNet 低于 GoogLeNet。传统卷积神经网络由于数据集过少、空间辨识度较差所以在实验中模型过拟合导致平均准确率较差,但改进胶囊网络凭借其优势在少量数据

集的训练过程中达到了较高的准确率。综合来看改进胶囊网络在少量电力线异物识别数据集的实验表现认为最优。

### 3.5 模型性能实验

由于巡线无人机飞行高度频繁变化、拍摄角度多种多样、工作时间段不同。因此对数据集进行加工来模拟异物大小不同、异物角度不同、光强不同情况下的测试数据进行模型性能测试,部分模拟后的测试数据如图 10 所示。




图 10 部分模拟后的测试数据

Fig. 10 Test data after partial simulation

设置小图像数据、中图像数据、大图像数据、旋转 90°、水平翻转、竖直翻转、低光强、中光强、高光强环境下各 100 张测试数据样本。其中包含 60 张无异物数据样本、10 张风筝样本、10 张冰柱样本、10 张鸟巢样本、10 张塑料样本,测试结果如表 4 所示。

表 4 模型性能测试结果

Table 4 Model performance test results

测试种类	无异物	风筝	冰柱	鸟巢	塑料	正确数
小图像	58	9	8	7	9	91
中图像	59	8	9	8	10	94
大图像	58	10	8	7	9	92
旋转 90°	57	8	10	9	8	92
水平翻转	59	9	9	10	8	95
竖直翻转	58	8	7	9	10	92
低光强	50	7	6	8	7	78
中光强	58	8	9	7	10	92
高光强	51	6	7	5	7	76

由表 4 可知,低光强、高光强数据对模型准确率影响较大,数据的大小、翻转情况下模型均可稳定检测,基本不影响准确率。

## 4 结 论

针对传统卷积神经网络空间辨识度差、训练样本需求过多的问题。首先提出了自适应贡献池化的改进使得异物识别平均准确率提升,其次提出电力线异物深度特征提取单元对数据图像进行深度特征提取并改进主胶囊层和动态路由结构以适应二分类的电力线异物识别。改进胶囊网络平均异物识别平均准确率为 98.2%,平均训练时间为 2 677 s 相比传统胶囊网络平均准确率提高 3.6%。在少样本的深度学习过程中,胶囊网络优于 AlexNet、GoogLeNet,训练样本需求量少。最后针对大小、角度、光照不同的数据样本进行模型性能测试。结果表明改进胶囊网络应用于巡线检测中可以避免人工巡线的艰苦工作环境,提高巡线效率。解决了传统卷积神经网络训练样本需求过多的问题,使得训练过程更加容易。解决了无人机获取电力线数据时的角度、空间位置不同而对传统卷积神经网络模型带来的影响,使得角度不同、大小不同、位置不同的异物检测结果更准确。改进胶囊网络在电力线异物识别的空间辨识能力较好,训练数据需求量少,具有实际工程实用价值。如果继续优化改进卷积神经网络的动态路由结构,采用更深层次的数据算法会进一步增加平均准确率。模型也可以通过更好的数据预处理方法使得模型在光强变化大的前提下也具有一定的鲁棒性。

## 参考文献

- [ 1 ] 易茂祥,陶金,吴友杰,等.一种基于电力线的现场总线设计与仿真[J].电子测量与仪器学报,2015,29(2):258-264.  
YI M X, TAO J, WU Y J, et al. Design and simulation for a power lines based fieldbus[J]. Journal of Electronic Measurement and Instrumentation, 2015, 29(2):258-264.
- [ 2 ] 谢剑锋,闫军,卢旻.高压电流互感器运行状态检测新技术及应用[J].电子测量技术,2016,39(7):169-173.  
XIE J F, YAN J, LU M. New technology and application of high voltage current transformer running state[J]. Electronic Measurement Technology, 2016, 39(7):169-173.
- [ 3 ] 陈宜文,许斌,郝建华,等.基于 OFDM 技术的电力线通信系统建模与仿真[J].国外电子测量技术,2015,34(2):21-26.  
CHEN Y W, XU B, HAO J H, et al. Modeling and simulation of power line communication system based on OFDM technology[J]. Foreign Electronic Measurement Technology, 2015, 34(2):21-26.
- [ 4 ] 高强,阳武,李倩.DBN 层次趋势研究及其在航拍图像故障识别中的应用[J].仪器仪表学报,2015,36(6):1267-1274.  
GAO Q, YANG W, LI Q. Research on deep belief network layer tendency and its application into identifying fault images of aerial images[J]. Chinese Journal of Scientific Instrument, 2015, 36(6):1267-1274.
- [ 5 ] CAI Q Y, DING X B. Application of robust regression estimation in moving background compensation [C]. International Conference on Instrumentation and Measurement, Computer Communication and Control (IMCCC), 2016:65-68.
- [ 6 ] WANG W G, ZHANG J J, HAN J, et al. Broken strand and foreign body fault detection method for power transmission line based on unmanned aerial vehicle image [J]. Journal of Computer Applications, 2015, 35(8):2404-2408.
- [ 7 ] 金立军,姚春羽,张文豪.基于航拍图像的输电线路异物识别[J].同济大学学报(自然科学版),2013,41(2):277-281.  
JING L J, YAO CH Y, ZHANG W H. Recognition of extra matters on transmission lines based on aerial images [J]. Journal of Tongji University (Natural Science Edition), 2013, 41(2):277-281.
- [ 8 ] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Image net classification with deep convolutional neural networks [C]. Advances in Neural Information Processing Systems, 2012:1097-1105.
- [ 9 ] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015:1-9.
- [ 10 ] HINTON G E, KRIZHEVSKY A, WANG S D. Transforming auto-encoders [C]. International Conference on Artificial Neural Networks, 2011:44-51.
- [ 11 ] SABOUR S, FROSST N, HINTON G E. Dynamic routing between capsules [C]. Advances in Neural Information Processing Systems, 2017:3856-3866.
- [ 12 ] 周飞燕,金林鹏,董军.卷积神经网络研究综述[J].计算机学报,2017,40(6):1229-1251.  
ZHOU F Y, JIN L P, DONG J. Review of convolutional neural network [J]. Journal of Computers, 2017, 40(6):1229-1251.
- [ 13 ] 刘万军,梁雪剑,曲海成.不同池化模型的卷积神经网络学习性能研究[J].中国图象图形学报,2016,21(9):1178-1190.  
LIU W J, LIANG X J, QU H CH. Learning performance of convolutional neural networks with different pooling

models [ J ]. Journal of Image and Graphics, 2016, 21(9):1178-1190.

- [ 14 ] ZHAO Y, BIRDAL T, DENG H, et al. 3D point capsule networks [ C ]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2019: 1009-1018.
- [ 15 ] LI Y, YUAN Y. Convergence analysis of two-layer neural networks with reLU activation [ C ]. Advances in Neural Information Processing Systems, 2017: 597-607.

作者简介



宋立业, 1990 年于辽宁工程技术大学获得学士学位, 2001 年于西安交通大学获得硕士学位, 2018 年于辽宁工程技术大学获得博士学位, 现为辽宁工程技术大学副教授, 主要研究方向为智能电网新技术。

E-mail: 372492761@qq.com

**Song Liye** received his B. Sc. degree from Liaoning Technical University in 1990, M. Sc. degree from Xi'an Jiaotong University in 2001, and Ph. D. degree from Liaoning Technical University in 2018. Now he is an associate professor at Liaoning Technical University. His main research interest includes new smart grid technology.



王诗翱, 2016 年于辽宁工程技术大学获得学士学位, 现为辽宁工程技术大学硕士研究生, 主要研究方向为智能电网新技术、模式识别, 图像处理。

E-mail: Lannister0910@163.com

**Wang Shiao** received his B. Sc. degree from Liaoning Technical University in 2016. He is a M. Sc. at Liaoning Technical University. His main research interest includes new smart grid technology, pattern recognition, image processing.



刘昕明, 于 2006 年于辽宁工程技术大学获得学士学位, 2009 年于辽宁工程技术大学获得硕士学位, 2014 年于东北大学获得博士学位, 现为辽宁工程技术大学讲师, 主要研究方向为工业过程检测、建模与控制。

E-mail: liuxin\_ming@163.com

**Liu Xinming** received his B. Sc. degree from Liaoning Technical University in 2006, M. Sc. degree from Liaoning Technical University in 2009, and Ph. D. degree from Northeastern University in 2014. Now he is a lecturer at Liaoning Technical University. His main research interest includes industrial process detection, modeling and control.