

DOI: 10. 13382/j. jemi. B2104729

基于改进胶囊网络的运维知识库故障分类方法^{*}

赵迪 王呈
(江南大学物联网工程学院 无锡 214122)

摘 要:针对传统运维知识库不具备图像故障现象识别能力,无法处理非结构化数据的问题,基于深度学习的故障分类网络,提出改进胶囊网络特征提取结构的 Caps-DRFN 算法,实现机电设备运维图像自动分类。首先,针对运维图像存在的多噪声问题,引入深度残差收缩网络(deep residual shrinkage networks,DRSN)提高模型在含噪声数据上的特征提取效果。然后,针对实际拍摄的运维图像多尺度问题,结合 FPN(feature pyramid networks)算法,实现图像多尺度特征融合提高模型分类准确率。最后,利用胶囊结构构建向量神经元,通过动态路由的特征传递方式,得到分类结构数字胶囊,实现机电设备故障分类。实验结果表明,相较于传统胶囊网络算法,提出的基于特征融合的 Caps-DRFN 算法准确率提高了 15%且有着更强的鲁棒性。

关键词:故障分类;FPN;DRSN;胶囊网络;特征提取

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 520. 6040

Fault classification method of operation and maintenance knowledge base on improved capsule networks

Zhao Di Wang Cheng
(School of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China)

Abstract: Traditional operation and maintenance knowledge base does not have the ability to identify the failure phenomena in the image. Therefore, the knowledge base cannot handle the problem of unstructured data. To tackle this issue, based on fault classification networks in deep learning, an improved capsule network feature extraction structure based Caps-DRFN algorithm is proposed, which can realize automatic classification of operation and maintenance images of electromechanical equipment. Firstly, aiming at the multi-noise problem of operation and maintenance images, the deep residual shrinkage networks (DRSN) are introduced to improve the feature extraction performance of the model on noisy data. Subsequently, for the multi-scale problem of actual shooting operation and maintenance images, through the combination of the feature pyramid networks (FPN) algorithm, the Caps-DRFN realizes image multi-scale feature fusion and improves the accuracy of model classification. Finally, the vector neuron is constructed by using the capsule structure, and the digital capsule of the classification structure is obtained through the feature transmission method of dynamic routing. The model realizes the fault classification of electromechanical equipment. The experimental results show that compared with the traditional capsule network algorithm, the accuracy of the proposed Caps-DRFN algorithm based on feature fusion is increased by 15% and it is more robust.

Keywords: fault classification; FPN; DRSN; capsule networks; feature extraction

0 引 言

机电设备是公用设施的命脉,当前的趋势是进一步构建运维知识库,将运维管理推向智能化。

收稿日期:2021-09-13 Received Date: 2021-09-13

^{*} 基金项目:近地面探测技术重点实验室预研基金(6142414180104)、轨道交通运行控制系统国家工程技术研究中心开放课题(NERC2019K001)

发征兆对应的故障现象,在匹配故障现象后将该故障现象对应的故障原因及处理措施或维修意见推送给运维人员。然而,传统知识库系统仅能处理物联网平台接收的结构化数据,例如,电流越限、开关跳闸等,对于故障图像这类非结构化数据传统知识库无法有效处理。因此,本文提出建立基于图像分析的运维知识库系统,利用运维图像数据,结合图像分类算法,将分类结果作为故障现象融入传统知识库系统知识库,既完善了知识库系统功能也提高了运维效率。分类算法作为该系统的核心,对知识库性能的优劣起着关键性作用。

随着深度学习技术的不断发展,卷积神经网络在数据量充足时已经有着足够稳定的表现,然而在复杂小样本数据集上的分类效果往往并不理想。公用设施运维知识库系统构建初期,样本量通常不足,如何在有限样本下提升分类准确率是必须考虑的问题。不同于迁移学习^[2]、样本增强^[3]等方法,Geoffrey Hinton 等在 2017 年提出了胶囊网络(capsule networks, CapsNet)^[4]结构,与传统 CNN 相比,该网络使用向量神经元替代传统的标量神经元,不仅能够以特征响应的强度来表示图像,还能够表征图像特征的方向、位置等信息^[5],由于考虑了特征的空间相关性,胶囊网络训练所需的数据量也大幅减少。同时,胶囊网络采用动态路由算法取代传统卷积神经网络中的最大池化法,较好地保留了图像通道特征及其空间结构特征,防止丢失过多的有效信息^[6]。文献[7]优化了胶囊网络的特征提取结构,并提出了一种自适应贡献池化的方法避免特征信息的丢失,通过实验证明了胶囊网络更适用于空间辨识要求度高、数据量有限的电力线异物识别问题。文献[8]将胶囊网络应用于植物图像识别,并提出局部约束动态路由算法取代经典动态路由算法中的全连接结构,在分类精度和模型参数指标上均得到大幅提升。

现有深度学习方法的有效性依赖于对训练数据集的高质量要求,当训练集呈现蕴含复杂噪声、异常点入侵、类别不均衡等问题时,其有效性往往无法得以保证,这被称之为深度学习的鲁棒性问题。机电设备所处环境较为复杂,光照、视角等影响因素导致图像数据往往存在过多的噪声像素。目前的解决方法可分为传统模型驱动方法和现代数据驱动方法。模型驱动方法针对不同图像噪声进行建模,通过设计图像去噪算法得到预期的无噪图像。常见的图像去噪方法可分为滤波去噪、稀疏编码去噪、外部先验去噪以及低秩去噪 4 类^[9]。这类图像去噪方法多涉及手工选择参数,存在无法获得图像全局特征等问题。相对于传统模型驱动方法,数据驱动方法通过构建通过端到端的训练,获得对噪声图片能够直接输出无噪图片的深度网络预测模型,不仅可以拟合复杂噪声分布,还节

省了计算时间^[10]。其中基于自编码(auto-encoder, AE)网络^[11-13]、卷积神经网络(convolutional neural networks, CNN)^[14-16]等方法被广泛应用于图像去噪领域。深度残差收缩网络(deep residual shrinkage networks, DRSN)^[17]是深度残差网络^[18]的一种的改进版本,通过集成深度残差网络、注意力机制和软阈值函数的方法使模型能够通过训练得到自适应的阈值,能够很好地应对图像分类任务中样本噪声导致的鲁棒性问题。文献[17]将深度残差收缩网络应用于轴承故障诊断,得出深度残差收缩网络对于混合有复杂噪声的信号更能有效提取故障特征的结论。文献[19]将深度残差收缩网络用于 Hep-2 细胞模式识别,通过实验证明深度残差收缩网络具有良好的去噪能力。

运维人员在拍摄设备故障图像时,由于拍摄距离原因,同一故障设备在不同图像中的尺寸差异较大,这类图像多尺度问题往往导致分类网络训练效果不佳。特征金字塔是解决该问题的有效途径,文献[20]提出了基于特征金字塔的多尺度图像识别方法 SSD(single shot detector),根据原始图像生成多个不同尺度的特征图像,而后从多个不同尺度的特征图识别不同尺度的物体。然而,浅层特征映射中的小尺度语义信息限制了 SSD 的分类和回归能力。文献[21]提出的 FPN 算法通过简单的网络连接改变,在基本不增加原有模型计算量情况下,大幅度提升了小物体检测的性能。

针对处理运维图像中亟需解决的小样本、多噪声、多尺度 3 大问题,本文提出在适合小样本分类的胶囊网络基础上,结合深度残差收缩网络解决图像噪声导致的模型鲁棒性问题,同时融入 FPN 算法解决图像多尺度问题,进而提高胶囊网络的分类准确率。通过构建 Caps-DRFN(deep residual shrinkage fusion capsule network)模型实现运维故障图像分类,将分类结果作为故障现象融入传统知识库系统,解决传统知识库无法处理非结构化数据的问题。

1 面向运维图像分类的改进胶囊网络

本文在文献[4]提出的经典胶囊网络结构基础上,改进了网络的特征提取结构,并基于 FPN 特征融合策略设计了多维度胶囊,改进后的 Caps-DRFN 框架如图 1 所示。模型首先通过深度残差收缩模块替代经典胶囊网络单一卷积结构实现图像深层特征的提取,利用自适应阈值的结构对无效特征进行过滤,增强模型抗噪声干扰能力。接着结合 FPN 算法实现特征融合,解决多尺度图像的特征提取问题。得到多尺度特征后编码为多维度胶囊结构,借助动态路由算法实现胶囊间特征传递得到分类

胶囊,最后通过解码实现运维图像分类。对于小样本数据导致模型过拟合问题,在模型训练阶段在经典胶

囊网络损失函数基础上进行了调整以提高模型泛化能力。




图 1 Caps-DRFN 网络框架示意图

Fig. 1 Framework diagram of the Caps-DRFN network

1.1 面向特征提取的 DRSN 模块

类似泵房这类昏暗光照条件下拍摄的图像样本,多包含较多的噪声像素,导致网络提取到过多的无用特征,影响模型的分类精度及鲁棒性。为了提高模型在含噪数据上的分类效果,本文提出了改进的 DRSN 模块作为网络特征提取结构。通过引入“软阈值化”作为“收缩层”,采用自适应设置阈值的方法使得网络具有去除噪声的能力。

采用文献[17]中的 RSBU-CW 结构作为本文的深度残差收缩网络基本模块,使用 3 层残差收缩学习单元,最终构建的 DRSN 特征提取网络架构如图 2 所示,包含 3 个输出 256 个特征图的残差单元、4 个输出 512 个特征图的残差单元、6 个输出 1 024 个特征图的残差单元、3 个输出 2 048 个特征图的残差单元。

1.2 面向特征融合的 FPN 结构

由于拍摄位置差异,同一设备故障图像存在尺度不一的情况。对于特征提取网络而言,深层和浅层网络提取的特征包含的信息受物体尺度的影响较大,如果仅使用特征提取网络的最后一层进行分类,分类效果会受到影响。本文将 FPN 特征融合算法应用于胶囊网络以解决图像多尺度问题。

根据文献[21]提出的 FPN 结构,设计的改进胶囊

网络在使用深度残差收缩网络进行特征提取后,构建特征金字塔进行特征融合,整体结构如图 3 所示,在对输入的图片进行 5 种层次的卷积运算,提取得到 c1~c5 五种尺寸的特征图后利用 c2~c5 进行特征融合操作,通过卷积操作将通道数调整为 256,将 c5 特征图进行上采样后与 c4 特征图进行融合,将所得融合后的特征图经过上采样后再与 c3 进行融合,以此类推,使得每一层的特征图都融合高层的语义特征。之后每一层特征图都采用一个 3×3 的卷积用来消除不同层之间的混叠效果,起到缓冲与进一步融合的作用,最终得到各层特征 p2~p5 作




图 2 深度残差收缩网络基础网络架构

Fig. 2 The basic network architecture of the deep residual shrinkage network

为胶囊网络的输入。

1.3 面向图像分类的胶囊网络

针对本文的运维图像多分类问题,提取到各层特征后,将特征信息分别编码到多维初级胶囊中,通过变换矩阵得到预测胶囊,使用动态路由算法实现胶囊间的特征传递获得合适的分类胶囊,最后交给解码器解码完成图像的准确分类。

1) 多维特征胶囊

将特征信息编码到多维初级胶囊中,通过权重矩阵得到预测胶囊,转换公式为:

$$\hat{u}_{ji}^k = \mathbf{W}_{ij}^k u_i^k (k = 1, 2, 3, 4) \quad (1)$$

$$\hat{\mathbf{u}} = \text{concat}(\hat{\mathbf{u}}^k) \quad (2)$$

其中, $\mathbf{W}^k$ 是 $\mathbf{u}^k$ 和 $\hat{\mathbf{u}}^k$ 间的权重矩阵。 $\mathbf{u}_i^k$ 代表由第 k




图3 特征提取网络整体结构示意图

Fig. 3 Schematic diagram of the overall structure of the feature extraction network

层特征图得到的第 i 个胶囊。 $\hat{\mathbf{u}}_{ji}^k$ 表示由第 k 层特征图第 i 个子胶囊通过变换矩阵得到的第 j 个预测胶囊,每层的初级胶囊通过不同的仿射变换得到该层的预测胶囊, $\hat{\mathbf{u}}$ 是该多尺度胶囊编码结构的输出,由各层预测胶囊拼接得到。在训练过程中,部分整体关系通过调整矩阵 $\mathbf{W}_{ij}^k$ 来学习。

2) 动态路由算法

在上一节中,通过权重矩阵得到预测胶囊 $\hat{\mathbf{u}}$,而动态路由算法则实现预测胶囊与最终的分类胶囊之间的向量式传递。具体算法如下:

(1) 初始化 l 层第 i 个胶囊和 $l+1$ 层第 j 个胶囊间特征传递参数 b_{ij} 为 0;

(2) 假设有 k 个胶囊,利用 softmax 方式计算两层胶囊间权重 c_{ij} ,具体公式为:

$$c_{ij} = \frac{\exp(b_{ij})}{\sum_{i=1}^k \exp(b_{ij})} \quad (3)$$

(3) 传递低层胶囊特征 $\mathbf{u}_i$ 至高层胶囊,得到高层特征:

$$\mathbf{s}_j = \sum_{i=1}^k c_{ij} \hat{\mathbf{u}}_{ji} \quad (4)$$

(4) 压缩高层胶囊特征,得到压缩后的特征:

$$\mathbf{v}_j = \frac{\|\mathbf{s}_j\|^2}{1 + \|\mathbf{s}_j\|^2} \frac{\mathbf{s}_j}{\|\mathbf{s}_j\|} \quad (5)$$

(5) 迭代更新公式为:

$$b_{ij} = b_{ij} + \hat{\mathbf{u}}_{ji} \cdot \mathbf{v}_j \quad (6)$$

通过路由算法更新胶囊间的耦合系数 c_{ij} ,最终得到分类胶囊 $\mathbf{v}_j$ 的模长代表实体存在的可能性。

3) 损失函数

为了防止特征融合策略可能导致的特征冗余,使模型存在过拟合风险。本文在经典胶囊网络的 Margin loss 损失函数中加入了 L1 正则化损失项,对参数稀疏化以实现特征的自动选择,损失函数公式如下:

$$L_k = T_k \max(0, m^+ - \|\mathbf{v}_k\|)^2 + \lambda (1 - T_k) \max(0, \|\mathbf{v}_k\| - m^-)^2 + \|\mathbf{W}\|_1 \quad (7)$$

式(7)中, k 是分类数, T_k 表示类是否存在, m^+ 为上界,取值 0.9, m^- 为下界,取值 0.1, λ 是比例系数设置为 0.5, $\|\mathbf{v}_k\|$ 代表该胶囊单元属于该类别的概率, $\|\mathbf{W}\|_1$ 为权重参数的 L1 正则化损失。

2 实验结果与分析

2.1 实验环境及数据集

本次实验使用 Python3.6+Pytorch1.0 搭建网络,并在 Centos7 系统下运行。硬件方面,使用 12 G 显存的 GeForce GTX TITAN X 显卡进行网络训练。

实验数据主要采用无锡市中央车站机电设备运维消缺故障图像,部分样本来源于运维人员通过机电管家 App 上报的故障图像,包括空调、消防、排水系统中的共 5 类典型故障。其中,排水、空调系统由于设备安装位置原

因,部分样本存在明显的模糊和背光等噪声问题,且包含较多的多尺度图像;部分设备如空调系统比例阀控制线路板锈蚀收集的样本量较少,而消防系统的各类阀门设备由于使用时间较长的缘故损坏率较高,样本数据相对较多。为平衡样本数量,通过随机裁剪、旋转等数据增强方法进行样本扩充,剔除无用样本后,实验数据集样本分布如表 1 所示。

表 1 数据集信息

Table 1 Dataset information

设施系统	故障类型	类别	原始样本量	扩充后样本量
消防系统	闸阀损坏	1	800	2 182
排水系统	水泵损坏	2	500	2 038
	浮球损坏	3	300	2 256
空调系统	冰槽顶部锈蚀	4	400	2 500
	比例阀控制线路板锈蚀	5	200	1 969

2.2 对比实验

1) 运维知识库故障分类效果对比

为了测试所提出的改进模型对运维知识库故障的分类效果,分别选用 ResNet50、AlexNet、经典胶囊网络、改进胶囊网络在表 1 运维故障数据集上进行测试对比,对 5 类典型故障均按照 8 : 2 的比例划分训练集及测试集。引入总体测试精度以及 Macro-F1 值^[22]作为模型评价指标。

对比结果如表 2 所示。从测试集准确率对比可以看出,胶囊网络的识别准确率高于传统卷积网络,说明空间位置特征的提取有利于提高小样本数据下的分类精度。本文提出的 Caps-DRFN 网络在精度上比经典胶囊网络高 15%,证明提出的改进确实可以有效提高胶囊网络对运维故障图像的识别准确率。对比发现 Caps-DRFN 模型的 Macro F1 值高于其他模型,说明 Caps-DRFN 模型在本次实验中可靠性最高。

表 2 运维知识库故障识别精度与 Macro-F1 值

Table 2 Recognition accuracy and Macro-F1 value of operation and maintenance knowledge base failure

模型	测试精度	Macro-F1 值
ResNet50	0.67	0.651
AlexNet	0.61	0.608
CapsNet	0.75	0.748
Caps-DRFN	0.90	0.901

2) 模型鲁棒性验证

为了验证模型的鲁棒性,在表 1 的 5 类典型故障样本中各随机选出 20%作为测试样本。均加入不同等级的高斯噪声作为测试数据。图 4 给出水井浮球损坏故障图

像加入不同均值(μ)的高斯噪声示例,均值决定整个图像的明亮程度。图 5 为加入不同方差(σ)的高斯噪声示例,方差越大,数据越分散,图像的分辨率就越低,越模糊。通过调节高斯噪声参数模拟实际各类不同的拍摄环境。




图 4 添加不同均值高斯噪声的水井浮球损坏图像

Fig. 4 Images of well floating ball damaged with Gaussian noise of different mean




图 5 添加不同方差高斯噪声的水井浮球损坏图像

Fig. 5 Images of well floating ball damaged with Gaussian noise of different variances

选取 ResNet50、AlexNet、经典胶囊网络 (CapsNet) 以及本文提出的改进胶囊网络 (Caps-DRFN) 进行实验对比,通过调节均值和方差参数增强高斯噪声对测试集的干扰观察模型精度变化,进而比较模型鲁棒性。实验结果如图 6 所示。对比图 (a)、(b) (胶囊网络) 和图 (c)、(d) (传统 CNN) 发现,随着噪声均值和方差的增大,传统 CNN 模型对噪声变化较为敏感,在噪声方差为 0.06、均值为 2 时,精度下降已经较为明显,仅为 50% 左右,而胶囊网络的精度整体较传统 CNN 模型下降得慢,说明胶囊结构使模型具有一定的抗干扰能力。如图 6 (a) 所示,改进后的胶囊网络在噪声数据集上表现最优,当添加的噪声均值为 2、方差 0.12 时,经典胶囊网络准确率下降了 29%,改进胶囊网络准确率仅下降了 16%,仍保持在 74%。因此,实验结果表明本文提出的改进胶囊网络模型具有较强的鲁棒性。

3) 多尺度特征融合有效性验证

选取未采用 FPN 特征融合策略仅使用特征提取最后一层预测的 Caps-DRSN 模型与本文的 Caps-DRFN 模型进行特征融合有效性的验证,图 7 为两个模型提取的浮球损坏故障特征图谱,均选取特征提取网络各层第 1 张特征图谱进行对比,可以看出 FPN 融合策略增强了浅




图6 不同模型测试精度随噪声参数变化示意图

Fig. 6 Schematic diagram of the test accuracy of different models changing with the noise parameters

层网络的语义特征。




图7 使用 FPN 融合策略前后特征图谱

Fig. 7 Feature map before and after using FPN fusion strategy

排水系统和空调系统采集的故障样本中,由于拍摄角度、相机远近的影响多尺度样本较多,为了观察特征融合策略对各故障类别分类准确率的影响,在表1的5类典型故障样本中各随机选出20%作为测试样本,绘制以上两种模型对测试样本的混淆矩阵如图8所示。可以发现,使用特征融合策略后各类故障分类准确率均提升明显,例如故障3(浮球损坏故障)预测正确的数量从79增加至173,准确率提升了47%,表明多尺度特征融合策略有效提高了模型对多尺度图像的识别效果。

4) 模型泛化能力对比

由于实验数据集中部分样本缺乏,即便使用了数据增强方法,模型依然极易出现过拟合现象。图9为经典




图8 使用 FPN 融合策略前后模型混淆矩阵

Fig. 8 Model confusion matrix before and after using the FPN fusion strategy

胶囊网络在运维图像数据集下的损失图及精度变化曲线,可以看出,在训练100轮后,训练损失持续下降,训练集精度也接近99%,但测试损失值难以收敛,测试精度基本在60%左右不断波动,说明小样本下模型学习了过多无用的噪声信息,泛化能力弱,模型出现明显的过拟合情况。

为了对比模型泛化性能以及证明损失函数的有效性,选择3种不同胶囊网络模型进行分析,模型1为经典胶囊网络(CapsNet),模型2为改进特征提取结构但未加入L1正则化的胶囊网络,模型3为本文提出的加入L1正则化损失的Caps-DRFN模型,通过实验发现3种模型训练误差都在10%以下,图10为3种模型测试误差对比。

实验结果表明,模型2相对模型1而言,过拟合情况改善,在训练300轮后测试误差收敛于21%左右,比模型1低了19%左右,说明使用DRSN模块进行特征提取确实在提高特征提取能力的同时对无效特征进行过滤。模型3在测试集上的误差最终收敛于10%左右。比模型2低了11%,说明加入L1正则化对参数稀疏化确实




图9 经典胶囊网络训练结果对比

Fig. 9 Comparison of training results of capsule network




图10 不同胶囊网络测试误差对比

Fig. 10 Comparison of test errors of different capsule networks

可以进一步防止模型过拟合,提高模型泛化能力。

3 结论

本文面向中央车站机电设备设施系统运维,提出了一种改进胶囊网络算法实现机电设备故障分类,将分类结果作为故障现象融入传统知识库系统,辅助运维故障诊断。通过实验对比验证,可以得出以下结论:

1) 本文提出的 Caps-DRFN 模型具有较好的鲁棒性,在噪声干扰较大的运维图像数据集上仍保持较高的分类精度。

2) 特征融合策略增强了网络对浅层特征的利用,提升了 Caps-DRFN 模型在多尺度运维图像上的分类准确率。

3) 在实际运维故障图像分类任务上,Caps-DRFN 相比其他 CNN 模型在准确率和泛化能力上均有较大提升,

更适用于基于图像分析的运维管理知识库系统中的故障现象识别、诊断和处理应用。

为了进一步提高本文模型的性能,后期可以考虑以下两种思路进行进一步研究:

1) 扩充样本,后期可通过搜集更多具有代表性、高质量的故障图片以及结合更多数据增强方法进行测试观察精度的提升情况。

2) 尝试迁移学习方法,通过在大数据集上预训练一个较好的特征提取模块来提高本文模型在运维数据集上的精度。

参考文献

- [1] 曹永峰,翟峰,肖建红,等. 用电信息采集系统故障运维知识库的设计与应用[J]. 电力信息与通信技术, 2018, 16(3): 81-86.
CAO Y F, ZHAI F, XIAO J H, et al. Design and application of fault operation and maintenance knowledge base for electric information collection system [J]. Electric Power Information and Communication Technology, 2018, 16(3): 81-86.
- [2] 陈达,唐文虎,牛哲文. 基于深度学习的电力设备红外图像故障诊断方法[J]. 广东电力, 2021, 34(1): 97-105.
CHEN D, TANG W H, NIU ZH W. Fault diagnosis method for power equipment infrared images based on deep learning [J]. Guangdong Electric Power, 2021, 34(1): 97-105.
- [3] 李雅欣,侯慧娟,胥明凯,等. 基于策略梯度和生成式对抗网络的变压器油色谱案例扩充方法[J]. 电力自动化设备, 2020, 40(12): 211-217.
LI Y X, HOU H J, XU M K, et al. Oil chromatogram case generation method of transformer based on policy gradient and generative adversarial networks[J]. Electric Power Automation Equipment, 2020, 40(12): 211-217.
- [4] SABOUR S, FROSST N, HINTON G E. Dynamic routing between capsules [J]. ArXiv Preprint, 2017, arXiv: 1710.09829.
- [5] 贺文亮,朱敏玲. 胶囊神经网络研究现状与未来的浅析[J]. 计算机工程与应用, 2021, 57(3): 33-43.
HE W L, ZHU M L. Research status and future analysis of capsule neural network[J]. Computer Engineering and Applications, 2021, 57(3): 33-43.
- [6] 周恒,张春雷,张欣,等. 基于胶囊网络的碳酸盐岩储层岩性识别方法[J]. 天然气地球科学, 2021, 32(5): 685-694.
ZHOU H, ZHANG CH L, ZHANG X, et al. Lithology identification method of carbonate reservoir based on capsule network [J]. Natural Gas Geoscience, 2021,

- 32(5): 685-694.
- [7] 宋立业, 王诗翱, 刘昕明. 基于改进胶囊网络的电力线巡线异物检测[J]. 电子测量与仪器学报, 2020, 34(12): 49-56.
- SONG L Y, WANG SH AO, LIU X M. Detection of foreign objects in power line patrol based on improved capsule network[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(12): 49-56.
- [8] 温长吉, 娄月, 张笑然, 等. 基于改进稠密胶囊网络模型的植物识别方法[J]. 农业工程学报, 2020, 36(8): 143-155.
- WEN CH J, LOU Y, ZHANG X R, et al. Plant recognition method based on an improved dense CapsNet [J]. Transactions of the Chinese Society of Agricultural Engineering, 2020, 36(8): 143-155.
- [9] 刘利平, 乔乐乐, 蒋柳成. 图像去噪方法概述[J/OL]. 计算机科学与探索: 1-16 [2021-08-12]. <http://kns.cnki.net/kcms/detail/11.5602.TP.20210324.1115.010.html>.
- LIU L P, QIAO L L, JIANG L CH. Overview of Image denoising methods [J/OL]. Journal of Frontiers of Computer Science and Technology: 1-16 [2021-08-12]. <http://kns.cnki.net/kcms/detail/11.5602.TP.20210324.1115.010.html>.
- [10] 刘迪, 贾金露, 赵玉卿, 等. 基于深度学习的图像去噪方法研究综述[J]. 计算机工程与应用, 2021, 57(7): 1-13.
- LIU D, JIA J L, ZHAO Y Q, et al. Overview of image denoising methods based on deep learning[J]. Computer Engineering and Applications, 2021, 57(7): 1-13.
- [11] LEE D, CHOI S, KIM H J. Performance evaluation of image denoising developed using convolutional denoising autoencoders in chest radiography [J]. Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, 2018, 884: 97-104.
- [12] 张一飞, 陈忠, 张峰, 等. 基于栈式去噪自编码器的遥感图像分类[J]. 计算机应用, 2016, 36(S2): 171-174, 188.
- ZHANG Y F, CHEN ZH, ZHANG F, et al. Remote sensing image classification based on stacked denoising autoencoder [J]. Journal of Computer Applications, 2016, 36(S2): 171-174, 188.
- [13] 陈琦, 潘伟民. 基于自编码器的图像去噪设计与实现[J]. 新疆师范大学学报: 自然科学版, 2018, 37(2): 80-85.
- CHEN Q, PAN W M. Design and implementation of image denoising based on autoencoder [J]. Journal of Xinjiang Normal University (Natural Science Edition), 2018, 37(2): 80-85.
- [14] 唐家军, 刘辉, 胡雪影. 功能型复合深度网络的图像超分辨率重建[J]. 计算机科学与探索, 2020, 14(8): 1368-1379.
- TANG J J, LIU H, HU X Y. Image super-resolution reconstruction of functional composite deep network[J]. Journal of Frontiers of Computer Science and Technology, 2020, 14(8): 1368-1379.
- [15] ZHANG K, ZUO W, CHEN Y, et al. Beyond a gaussian denoiser: Residual learning of deep CNN for image denoising[J]. IEEE Transactions on Image Processing, 2017, 26(7): 3142-3155.
- [16] 吕永标, 赵建伟, 曹飞龙. 基于复合卷积神经网络的图像去噪算法[J]. 模式识别与人工智能, 2017, 30(2): 97-105.
- LYV Y B, ZHAO J W, CAO F L. Image denoising algorithm based on composite convolutional neural network [J]. Pattern Recognition and Artificial Intelligence, 2017, 30(2): 97-105.
- [17] ZHAO M, ZHONG S, FU X, et al. Deep residual shrinkage networks for fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2019, 16(7): 4681-4690.
- [18] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [19] 何涛, 陈剑, 闻英友. 基于深度残差收缩网络的HEp-2图像识别[J]. 计算机与现代化, 2021(1): 38-42.
- HE T, CHEN J, WEN Y Y. HEp-2 image recognition based on deep residual shrinkage network[J]. Computer and Modernization, 2021(1): 38-42.
- [20] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single shot multibox detector [C]. European Conference on Computer Vision. Springer, Cham, 2016: 21-37.
- [21] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2117-2125.
- [22] LIU C, WANG W, WANG M, et al. An efficient instance selection algorithm to reconstruct training set for support vector machine [J]. Knowledge-Based Systems, 2017, 116: 58-73.

作者简介



赵迪, 2017 年于南京工程学院获得学士学位, 现为江南大学硕士研究生, 主要研究方向为图像处理与模式识别。

E-mail: 1282060849@qq.com

Zhao Di received B. Sc. degree from Nanjing Institute of Technology in 2017. He is currently a M. Sc. candidate in Jiangnan University. His main research interests include image processing and pattern recognition.



王呈(通信作者), 2014 年于北京交通大学获得博士学位, 现为江南大学物联网工程学院副教授, 主要研究方向为非线性系统建模与控制、机器学习与数据挖掘。

E-mail: wangc@jiangnan.edu.cn

Wang Cheng (Corresponding author) received his Ph. D. degree from Beijing Jiaotong University in 2014. He is currently an associate professor at Jiangnan University. His main research interests include modeling and control of nonlinear system, machine learning and data mining.