

基于多尺度网络的绝缘子自爆状态智能认知方法研究*

万 涛¹,吴立刚¹,陆 烨²,王 浩²,张 潇²,范叶平¹,杨德胜¹

(1.国网信息通信产业集团安徽继远软件有限公司,安徽 合肥 230088;

2.国网江苏省电力公司徐州供电公司,江苏 徐州 221005)

摘要:针对已有绝缘子状态识别模型,以及深层网络尺度和交叉熵损失函数的缺陷,仿照运维人员检修模式,即依据评测结果的可信度动态决策,基于多尺度网络构建了一种绝缘子自爆状态智能认知方法。首先,面向定位归一化化预处理后的绝缘子图像,基于 ResNet-18 增加不同结构的网络分支提高网络适应不同分辨率的能力,同时在网络末端添加多尺度信息融合模块;其次,随机配置网络面向多个尺度特征,构建了泛化的自爆状态分类认知准则;最后,为了评测自爆状态分类认知结果的可信度,基于定义的误差指标自调节多尺度网络架构,重构不确定认知结果约束下的特征向量和分类认知准则,以进行自爆状态再认知。实验结果显示,与其他方法相比,所提出的智能认知方法增强了模型的泛化能力和认知精度。

关键词: 绝缘子状态;ResNet;反馈认知;多分辨率;多尺度

中图分类号: TP391

文献标识码: A

DOI:10.16157/j.issn.0258-7998.200223

中文引用格式: 万涛,吴立刚,陆烨,等. 基于多尺度网络的绝缘子自爆状态智能认知方法研究[J]. 电子技术应用, 2021, 47(8): 91–96.

英文引用格式: Wan Tao, Wu Ligang, Lu Ye, et al. Research on intelligent cognition method of insulator self-blast state based on multi-scale network[J]. Application of Electronic Technique, 2021, 47(8): 91–96.

Research on intelligent cognition method of insulator self-blast state based on multi-scale network

Wan Tao¹, Wu Ligang¹, Lu Ye², Wang Hao², Zhang Xiao², Fan Yiping¹, Yang Desheng¹

(1. Anhui Jiyuan Software Co., Ltd., State Grid Communication Industry Group Co., Ltd., Hefei 230088, China;

2. State Grid Xuzhou Electric Power Supply Company, Xuzhou 221005, China)

Abstract: In view of the drawbacks of the existing insulator state recognition models, and the scale and softmax loss function of deep network, imitating the mode of personnel operation and maintenance, that is, dynamic decision-making based on the credibility of the evaluation results, this paper constructs an intelligent cognition method of insulator self-blast states based on the multi-scale network. Firstly, for the pre-processed insulator images with localization and normalization, based on ResNet-18, branches with different network structure are added to improve the network ability to adapt to different resolutions. At the same time, the multi-scale information fusion module is added at the end of the network. Secondly, facing multiple scale features, stochastic configuration network(SCN) constructs a generalized cognition criterion of self-blast state classification. Finally, in order to evaluate the credibility of the self-blast state cognition result, based on the defined error index, the multi-scale network architecture is self-adjusted to reconstruct the feature vector and classification cognition criterion under the constraint of the uncertain cognition result, which carries out the self-blast state renewal cognition. The experimental results show that the proposed intelligent cognition method enhances the generalization ability and cognition accuracy compared with other methods.

Key words: insulator state; ResNet; feedback cognition; multi-resolution; multi-scale

0 引言

绝缘子作为输电电路中的重要器件,被安装在非等电位或导体与接地器件之间,其自爆与否会严重影响输电线路的安全^[1-3]。现代输电线路运维检修机制通常基

于直升机或无人机按照预定轨迹拍摄的视频,由人对每帧图像进行自爆绝缘子位置辨识。然而,人的主观因素,以及运维成本和复杂环境的客观因素,使得现代输电线路运维检修模式费时耗力。因此,亟待研究绝缘子自爆状态的智能认知方法。

目前学术界对绝缘子自爆状态的识别进行了大量

* 基金项目:江苏省电力有限公司科技项目(J2019062)

研究^[4-5]。然而,识别方法多基于理想条件,面对复杂野外图像时难以获取绝缘子状态的自曝特征,识别性能难以满足实际需求^[6-8]。

人工巡检从人工智能^[9-10]角度可归结为:人根据丰富的历史经验评判当前绝缘子状态。然而,这种主观估量模式易受不同人员经验、不确定干扰等因素影响,鲁棒性差。传统认知系统具有开环属性,针对输入的不确定对象,其恒定的特征提取和分类准则输出不确定的决策,无法模仿人类思维模式。随着神经网络算法的改进,深度学习受到了广泛关注^[11-12]。ResNet作为一个流行的网络结构,将原始输入信息直接传输到后续层,在生成泛化特征的同时,加快超深层网络的训练,然而,ResNet依然属于开环认知系统。

不同规模的网络提取不同尺度的特征融合后将改善整个网络性能^[13]。然而,当前的深度学习缺乏有效的方法提取多尺度特征提高图像的语义理解。因此,为了应对如上挑战,本文给出了一种基于多尺度卷积网络的绝缘子状态反馈认知方法。首先,面向定位归一化预处理后的绝缘子图像,基于ResNet-18增加不同结构的网络分支提高网络适应不同分辨率的能力,同时在网络末端,融合多尺度信息。其次,在面对绝缘子状态的多个尺度特征时,为了避免softmax逼近能力不足,随机配置网络(Stochastic Configuration Networks, SCN)^[14]可构建泛化的自曝状态分类认知准则。最后,为了评测自曝状态分类认知结果的可信度,基于定义的误差指标自调节多尺度网络架构,重构不确定认知结果约束下的特征向量和分类认知准则,以进行自曝状态再认知。实验结果显示,本文提出的智能认知方法与其他方法相比,增强了模型的泛化能力和认知精度。

1 基于多尺度神经网络的绝缘子自曝状态智能认知模型

本文提出的基于多尺度网络的绝缘子自曝状态智能认知方法的结构图如图1所示。

训练层基于ResNet-18的网络结构,通过添加不同分辨率的分支和网络末端的多尺度特征提取,构建多尺度特征融合模块组。

度结构卷积模型。并基于反馈层评测指标下达的网络深度,增加卷积层建立更深层次特征空间的数据结构。测试绝缘子图像亦可获取特定深度条件下的自曝状态认知结果。

反馈层仿人思维交互模式,通过定义误差指标实时评测认知结果的可信度,若不满足阈值指标,则自寻优调节网络深度,构建可信度不足测试样本的优化特征和分类认知准则,再认知自曝状态。

2 图像预处理

2.1 图像旋转

航拍中会时常遭遇气流,或由于轨迹变化位于不同方位。为了增强模型的鲁棒性,首先对训练集的图像进行 $\pm 5^\circ$ 、 $\pm 10^\circ$ 和镜像旋转,扩充样本集合,如图2所示。

2.2 绝缘子串定位

在航拍的线路巡检图像中绝缘子具有多种位姿,因此需要首先对其进行定位。图3给出了采用YOLO目标检测的定位效果。

2.3 绝缘子图像归一化

选取定位分割后的绝缘子串图像的较短边,将其定为299,较长边随较短边等比例归一化,归一化的绝缘子图像大小设定为 299×299 。

3 多分辨率多尺度架构 ResNet 网络

本文构建了如图4所示的多分辨率多尺度结构的ResNet网络(Multi-Resolution And Multi-Scale ResNet, MRMSRN)。

3.1 多分支网络架构

每个输出通道对应一个滤波器,共享参数的相同滤波器仅能提取一种类型特征送至输出通道。卷积层增加输出通道数量的代价是计算量剧增和过度拟合。在本研究中,借鉴NIN^[15]的思想,将非对称稀疏连接架构添加至ResNet的结构中,获取不同分辨率下的深度特征信息。

3.2 多尺度特征融合

原始ResNet网络基于单尺度决策层描述获取识别结果。然而,单一尺度无法确保认知所需的充分信息量。因此,针对上述多分支网络中提取的大小为 7×7 的特征

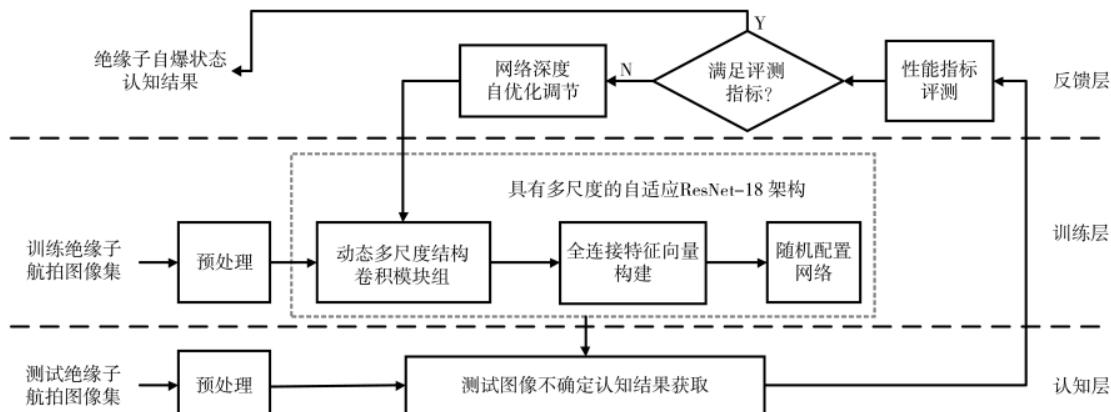
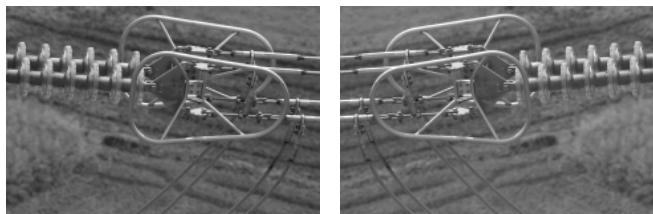
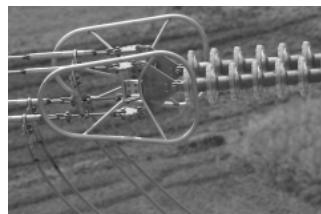


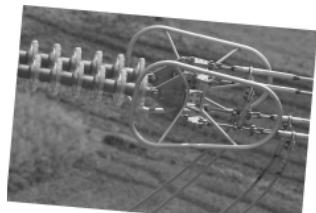
图1 基于多尺度网络的绝缘子自曝状态智能认知模型



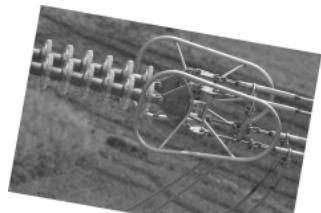
(a) 原图



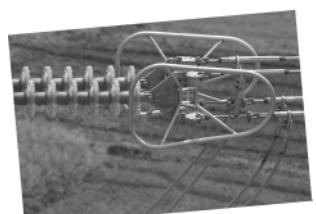
(b) 镜像图



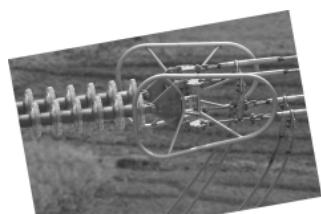
(c)+5°旋转



(d)+10°旋转

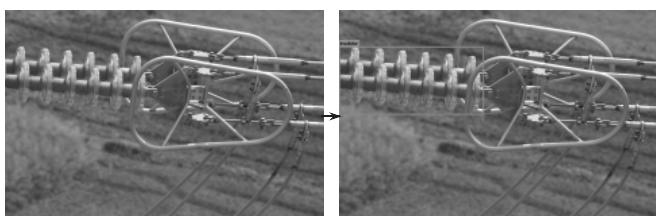


(e)-5°旋转

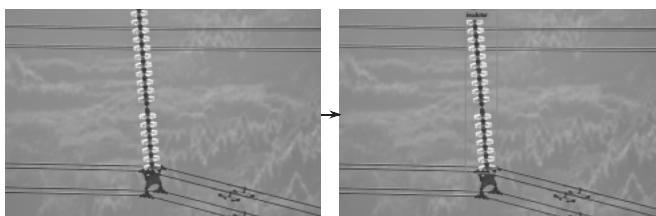


(f)-10°旋转

图 2 图像预处理



(a) 效果 1



(b) 效果 2

图 3 基于 YOLO 算法的航拍绝缘子定位

图输出,首先将其合并为 $8M \times 7 \times 7$ 的特征图集合,然后采用 7×7 和 4×4 的平均池化转换为两个不同尺度的特征向量,最终连接构建为 $40M$ 的全连接特征向量,输入后续模式分类器在多尺度条件下寻求绝缘子图像状态的最佳决策。

3.3 随机配置网络

近年来随着随机算法的涌现,多层次感知机的构建过程首先是预设一个参数区间,在此区间内以平均概率的方式生成感知机中输入层和隐含层所需的随机权参数,

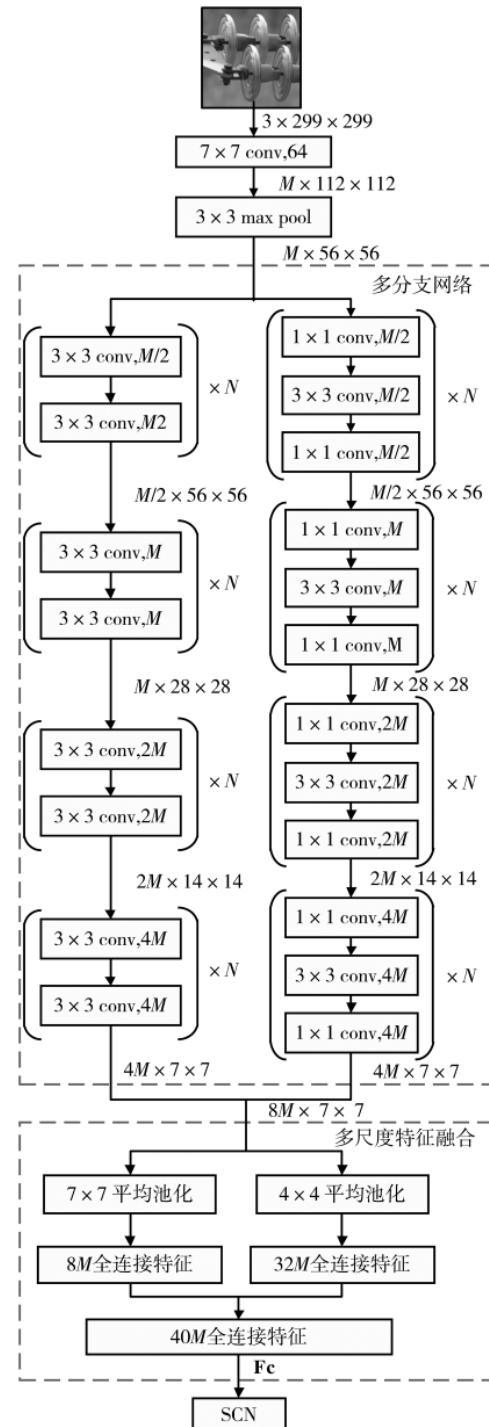


图 4 多分辨率多尺度架构 ResNet 网络流程图

采用最小二乘法计算伪逆的方式求取隐含层和输出层之间的权值。

设 $\mathbf{Fc} = \{\mathbf{Fc}_1, \mathbf{Fc}_2, \dots, \mathbf{Fc}_Z\}$ 是具有多分辨率多尺度的全连接特征向量, Z 是样本个数。SCN 可等效为如下网络:

$$f_L(\mathbf{Fc}) = \sum_{j=1}^L \beta_j k_j (\varphi_j^\top \mathbf{Fc} + b_j) \quad (1)$$

其中, $\beta = [\beta_1, \beta_2, \dots, \beta_L]$ 是输出层的权值; φ_j 和 b_j 是在预设区间内随机赋值的输入权值和隐含偏移; $\varphi_j, b_j \in [-\lambda, \lambda]$,

$\lambda]$, $k(\cdot)$ 是 sigmoid 函数; L 是隐含层节点个数。

3.4 深层神经网络参数调节

深层神经网络需要迭代参数, 优化策略如下:

(1) 前向传播中, 基于 MRMSRN 模型, 面向输入绝缘子图像集, 提取多分辨率多尺度特征。基于式(1)逐渐增加 SCN 的隐含层节点数, 直至满足最大个数或误差域值约束, 获取绝缘子自曝状态的认知结果;

(2) 若误差域值未满足, 且隐含层节点数已满足约束, 则基于 SCN 的输出误差反向更新 MRMSRN 的参数;

(3) 交替重复步骤(1)和(2), 直至误差不再改变, 输出最终认知结果。

4 绝缘子自曝状态智能认知机制

在获取测试绝缘子图像的自曝状态认知结果后, 需要构建性能指标实时评测绝缘子状态不确定认知结果的可信度, 为多分辨率多尺度特征空间的自寻优调节和分类认知准则重构提供依据, 仿人进行自曝状态再认知。

4.1 认知结果的误差指标

在第 ω 次认知中, 面对测试绝缘子图像集 U , $U_i \in U$, $i \in [1, Z]$, 网络深度 N 所生成的全连接特征向量 $\mathbf{Fc}_{i,N,\omega}$ 的不确定自曝状态认知结果为 $T_{i,N,\omega} \in [1, n_c]$, 其中 n_c 为自曝状态类别标签。潜在语义分析可以抽象 $\mathbf{Fc}_{i,N,\omega}$ 至压缩语义向量 $\mathbf{fc}_{i,N,\omega} = [\mathbf{fc}_{i,N,\omega,1}, \dots, \mathbf{fc}_{i,N,\omega,s}]$, $s=40M$ 。设与 $\mathbf{fc}_{i,N,\omega}$ 具有相同类别训练集的语义向量矩阵为 $\mathbf{fc}_{T_{i,N,\omega}}$, 则同类别误差矩阵 $D_{i,N,\omega}$ 定义为:

$$\begin{aligned} D_{i,N,\omega} &= \mathbf{1}_{N_{i,N,\omega}} \cdot \mathbf{fc}_{i,N,\omega} - \mathbf{fc}_{T_{i,N,\omega}} \\ &= \mathbf{1}_{N_{i,N,\omega}} \cdot [\mathbf{fc}_{i,N,\omega,1}, \dots, \mathbf{fc}_{i,N,\omega,s}] - \begin{bmatrix} \mathbf{fc}_{T_{i,N,\omega},1}^1 & \cdots & \mathbf{fc}_{T_{i,N,\omega},s}^1 \\ \vdots & \ddots & \vdots \\ \mathbf{fc}_{T_{i,N,\omega},1}^{n_{i,N,\omega}} & \cdots & \mathbf{fc}_{T_{i,N,\omega},s}^{n_{i,N,\omega}} \end{bmatrix} \end{aligned} \quad (2)$$

其中, $Z_{i,N,\omega}$ 表示与 U_i 具有一致状态的训练样本个数。同理可定义不同类别误差矩阵 $D_{i,N,\omega}^*$, 则 U_i 的认知结果误差定义如下:

$$R_{i,N,\omega} = -\log_2 \left(1 - \frac{|D_{i,N,\omega}|}{|D_{i,N,\omega}| + |D_{i,N,\omega}^*|} \right) \quad (3)$$

其中, 熵值越大表示认知结果可信度越低, 需要增加网络深度以再认知状态, 反之亦然。

4.2 基于不确定认知结果误差熵的状态反馈调节机制

为了模仿人类反复推敲比对信息交互认知模式, 借鉴马尔科夫决策过程^[16]可定义性能指标 J :

$$J_\omega = \sum_{i=1}^Z R_{i,N,\omega} / d_\omega, \quad 1 \leq \omega \leq \omega_{\max} \quad (4)$$

其中, $R_{i,N,\omega} / d_\omega$ 表示测试图像在第 ω 次反馈认知过程中基于深度 N 的得分, $d(d<1)$ 是代价因子。特别地, $J_0 = \sum_{i=1}^Z R_{i,0}$ 表示初始卷积深度的得分。

5 实验结果

5.1 实验数据

从无人机的巡检航拍中选取包含绝缘子的 7 000 幅图像, 训练集与测试集的比例为 8:2, 每幅图像的尺寸为 4 288×2 848。MRMSRN 中卷积深度的最大值 $N_{\max}=6$, $M=32$, 训练数据重复的轮数为 100。SCN 中 φ_j 和 b_j 的取值范围 λ 为 {0.5, 1, 5, 10, 30, 50, 100}, $u_L=\{1=10^{-j}\}_{j=4}^7$, L 的最大值设为 1 000。由于 SCN 的参数设定具有随机性, 采用运行 10 次取最优结果的方式获取最佳参数组合。

5.2 实验结果分析

当网络深度 $N=1$ 时, 图 5 给出了 SCN 中采用不同隐含层节点个数 L 条件下, 训练绝缘子图像的自曝状态识别精度曲线。随着 L 个数的递增, 自曝状态的识别精度也随之增加; 当 L 超过 20 后, 识别精度呈现稳定收敛, 这一情形表明由于在 SCN 中不同参数的随机基函数引入, 使得输入多分辨率多尺度特征与输出自曝状态之间建立了有明确映射关系的非线性关系。

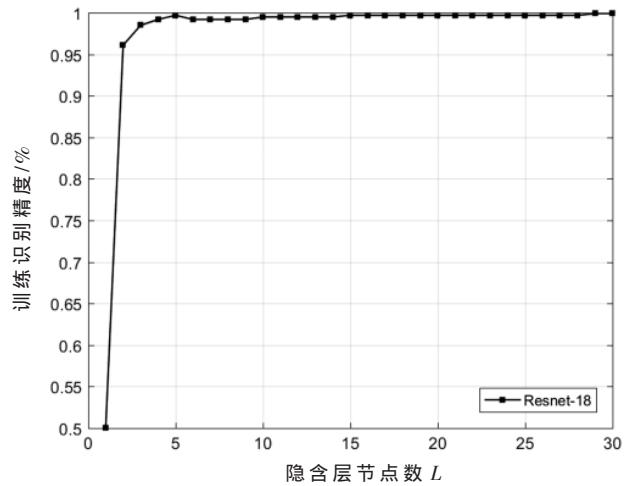


图 5 不同 L 的 SCN 检测精度比较

如图 6 所示, 不同的网络深度条件下, 随着 L 个数的增加, 检测精度均呈现单调递增快速收敛趋势。此外, 网络深度的增大使得绝缘子状态的检测精度先递增后稍微降低。当网络达到一定深度时, 可能会引入冗余信息致使性能饱和下降。初始网络深度为 ResNet-18 时, 即无反馈认知系统, 此时约有 90% 的正确输出, 剩余 10% 的测试样本, 通过反馈调节机制重构 SCN 后, 约 2% 的样本正确输出。

本文算法与其他算法的检测结果进行了比较, 包括带反馈环节的 ResNet-42、ResNet-18 和标准 ResNet-18, 以及 Inception-v3 和 VGG 16。表 1 给出了 500 次实验的平均检测精度和每幅图像的平均测试时间, 所给出的实验数据形式均采用均值±标准差。从表 1 可以明显看出, 本文方法的平均检测精度为 92.86%, 较基于反馈架构的其他模型提高了 2%~3%, 较基于无反馈架构的其他模型

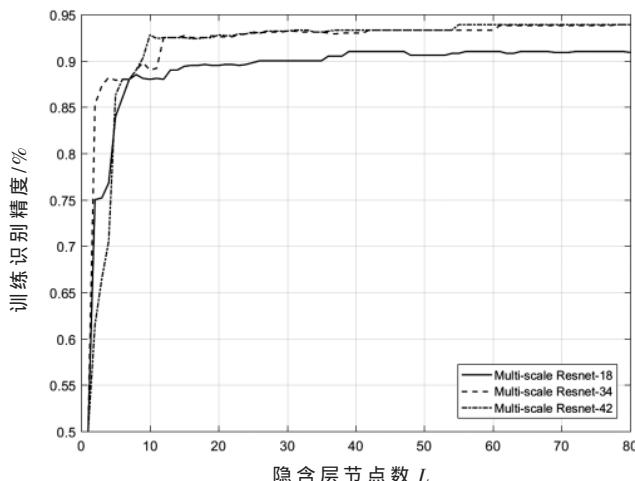


图 6 不同网络深度条件下的自曝状态识别精度曲线

表 1 不同深度学习模型的识别精度和训练时间比较

识别方法	识别率/%	测试时间/s
本文	92.86±0.03	0.26±0.02
ResNet-42-SCN	92.79±0.03	0.24±0.02
ResNet-18-SCN	90.71±0.04	0.20±0.02
ResNet-18	87.00±0.05	0.04±0.03
Inception-v3	85.78±0.06	0.09±0.02
VGG16	79.25±0.09	0.11±0.02

提高了 5%~13%。

此外,为了表征 SCN 对输入输出之间非线性关系的万局逼近能力,本文以相同的绝缘子图像作为输入,特征提取方法一致,分别采用 softmax、RVFL、SVM 和 KNN 模式分类器对自曝状态进行识别。从表 2 可以看出,SCN 较其他分类器具有更好的性能。主要原因是 SCN 在确保学习模型万局逼近能力的约束条件下,生成新的随机基函数,使得随机参数设置方法与建模数据关联。

表 2 不同模式分类器的识别精度和测试时间比较

识别方法	识别率/%	测试时间/s
SCN	92.86±0.03	0.26±0.02
softmax	92.41±0.04	0.26±0.02
RVFL	92.56±0.10	0.26±0.01
SVM	89.89±0.05	0.30±0.02
KNN	88.29±0.04	0.28±0.01

6 结论

本文探讨了一种基于多尺度卷积神经网络的绝缘子状态反馈认知方法的可行性和有效性。首先,基于改进的 ResNet 提取绝缘子图像多分辨率多尺度特征。然后,基于结构自生成的 SCN 模式分类器,在输入特征与输出自曝状态之间建立强泛化的非线性映射关系。最后,仿人思维模式构造误差指标,评测自曝状态认知结果的可信度,构建调节机制更新特征空间并重构分类准则,反馈再认知绝缘子状态。实验结果表明了本文方法的可行性和有效性。

航拍的图像中可能存在大量未知噪声,为了增强绝缘子自曝状态的检测精度,图像去噪将是下一步的研究重点。

参考文献

- [1] CHEN K L, GUO Y, MA X. Contactless voltage sensor for overhead transmission lines[J]. IET Generation Transmission & Distribution, 2018, 12(4): 957–966.
- [2] MOGI M, KAWAMURA M, YOSHIMI R, et al. A magnetic heterostructure of topological insulators as a candidate for an axion insulator[J]. Nature Materials, 2017, 16(5): 516–521.
- [3] DU C, VAN D S T, ZHOU T X, et al. Control and local measurement of the spin chemical potential in a magnetic insulator[J]. Science, 2017, 357(6347): 195–198.
- [4] ZHAO Z, NING L. The recognition and localization of insulators adopting SURF and IFS based on correlation coefficient[J]. Optik—International Journal for Light and Electron Optics, 2014, 125(20): 6049–6052.
- [5] ZHANG G, LIU Z, YE H. Automatic recognition for catenary insulators of high-speed railway based on contourlet transform and Chan-Vese model[J]. Optik—International Journal for Light and Electron Optics, 2016, 127(1): 215–221.
- [6] ALKALI A H, SAATCHI R, ELPHICK H, et al. Thermal image processing for real-time non-contact respiration rate monitoring[J]. IET Circuits Devices & Systems, 2017, 11(2): 142–148.
- [7] ABEED M A, BISWAS A K, AL-RASHID M M, et al. Image processing with dipole-coupled nanomagnets: noise suppression and edge enhancement detection[J]. IEEE Transactions on Electron Devices, 2017, 64(5): 2417–2424.
- [8] TAN S, SHEN Z. Hybrid problem-based learning in digital image processing: a case study[J]. IEEE Transactions on Education, 2017, 61(2): 127–135.
- [9] HE W, FENG Y, YU S, et al. Pattern recognition and classification of two cancer cell lines by diffraction imaging at multiple pixel distances[J]. Pattern Recognition, 2017, 61: 234–244.
- [10] HARDING S M, BENCI J L, IRIANTO J, et al. Mitotic progression following DNA damage enables pattern recognition within micronuclei[J]. Nature, 2017, 548(7668): 466–470.
- [11] BRONSTEIN M M, BRUNA J, LECUN Y, et al. Geometric deep learning: going beyond Euclidean data[J]. IEEE Signal Processing Magazine, 2017, 34(4): 18–42.
- [12] MAJUMDER N, PORIA S, GELBUKH A, et al. Deep learning-based document modeling for personality detection from text[J]. IEEE Intelligent Systems, 2017, 32(2): 74–79.
- [13] HOWARD K T, DUFFY B C, LINABURG M R, et al. Formation of DPM ethers using O-diphenylmethyl trichloroacetimidate under thermal conditions[J]. Organic &

Biomolecular Chemistry, 2016, 14(5): 1623–1628.

- [14] WANG D , LI M .Stochastic configuration networks: fundamentals and algorithms[J].IEEE Transactions on Cybernetics , 2017 , 47(10) : 3466–3479.
 - [15] HAN X M , DAI Q .Batch-normalized Mlpconv-wise supervised pre-training network in network[J].Applied Intelligence , 2017 , 48(1) : 142–155 .
 - [16] BUONGIORNO J , ZHOU M .Multicriteria forest decision making under risk with goal-programming Markov decision process models[J].Forest Science , 2017 , 63(5) : 474–484.

(上接第 90 頁)

能。其中 BLS 方法来自于文献[15], BLMMSE 方法来自文献[5]。从图 4 中可以看出, 在任何信噪比下, 生成式监督 DNN 模型的信道估计性能都优于 BLS 和 BLMMSE。此外, 本文还与未使用 1-比特 ADC 量化的最小二乘(Least Square, LS)估计进行了对比, 有趣的是, 所提的信道估计方法在 SNR 低于 14 dB 时, 性能始终优于未量化的 LS 估计。

4 结论

采用 1-比特 ADC 替代高分辨率 ADC 可以大幅度降低接收机成本和功耗,但使用传统方法,超大规模 MIMO 系统基站接收机在信道估计方面会造成严重的性能损失。本文利用生成模型和多层神经网络,提出了一种用于信道估计的生成式监督 DNN 模型。仿真结果表明,本文所提出的模型可以利用较少数量的导频得到较好的信道估计性能,即使存在 1-比特量化的非线性损害,仍然可以实现可靠的信道估计。

参考文献

- [1] WANG H , KOSASIH A , WEN C , et al. Expectation propagation detector for extra-large scale massive MIMO[J]. IEEE Transactions on Wireless Communications , 2020 , 19(3) : 2036–2051.
 - [2] CARVALHO E D , ALI A , AMIRI A , et al. Non-Stationarities in extra-large-scale massive MIMO[J]. IEEE Wireless Communications , 2020 , 27(4) : 74–80.
 - [3] ALI A , CARVALHO E D , HEATH R W . Linear receivers in non-stationary massive MIMO channels with visibility regions[J]. IEEE Wireless Communications Letters , 2019 , 8(3) : 885–888.
 - [4] RODRIGUES V C , AMIRI A , ABRAO T , et al. Low-complexity distributed XL-MIMO for multiuser detection[C]. 2020 IEEE International Conference on Communications Workshops (ICCWorkshops) , 2020 : 1–6.
 - [5] LI Y , TAO C , SECO-GRANADOS G , et al. Channel estimation and performance analysis of one-bit massive MIMO systems[J]. IEEE Transactions on Signal Processing , 2017 , 65(15) : 4075–4089.
 - [6] NEUMANN D , WIESE T , UTSCHICK W . Learning the MMSE

(收稿日期:2020-03-24)

作者简介:

万涛(1976-),男,硕士,高级工程师,主要研究方向:人工智能、移动互联网、网络空间安全。

吴立刚(1980-),通信作者,男,本科,工程师,主要研究方向:大数据、人工智能视频图像处理和分析,E-mail:leikowu@126.com。

范叶平(1979-),男,本科,工程师,主要研究方向:人工智能、移动互联网、网络安全。



扫码下载电子文档

channel estimator[J].IEEE Transactions on Signal Processing, 2018, 66(11): 2905–2917.

- [7] SOLTANI M ,POURAHMADI V ,MIRZAEI A ,et al.Deep learning-based channel estimation[J].IEEE Communications Letters ,2019 ,23(4) :652–655.
 - [8] ZHANG Y ,ALRABEIAH M ,ALKHATEEB A.Deep learning for massive MIMO with 1-bit ADCs ;when more antennas need fewer pilots[J].IEEE Wireless Communications Letters ,2020 ,9(8) :1273–1277.
 - [9] BALEVI E ,ANDREWS J G.One-bit OFDM receivers via deep learning[J].IEEE Transactions on Communications ,2019 ,67(6) :4326–4336.
 - [10] HAN Y ,JIN S ,WEN C ,et al.Channel estimation for extremely large-scale massive MIMO systems[J].IEEE Wireless Communications Letters ,2020 ,9(5) :633–637.
 - [11] BUSSGANG J J.Crosscorrelation functions of amplitude-distorted Gaussian signals[Z].MIT Research Laboratory Technical Report ,1952.
 - [12] PAPOULIS A ,PILLAI S U.Probability ,random variables ,and stochastic processes[M].Tata McGraw–Hill Education ,2002.
 - [13] HE K ,ZHANG X ,REN S ,et al.Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR) ,2016 :770–778.
 - [14] GOODFELLOW I ,BENGIO Y ,COURVILLE A ,et al.Deep learning[M].MIT Press ,Cambridge ,2016.
 - [15] RISI C ,PERSSON D ,LARSSON E G.Massive MIMO with 1-bit ADC[J].arXiv preprint arXiv :1404.7736 ,2014

(收稿日期:2021-01-28)

作者简介

蒲旭敏(1983-),通信作者,男,博士,讲师,主要研究方向:B5G/6G移动通信理论与关键技术、机器学习在移动通信中的应用,E-mail:puxm@cqupt.edu.cn。

吴超(1993-),男,硕士,主要研究方向:基于深度学习的大规模MIMO系统信道估计。

杨小珑(1997-),男,硕士,主要研究方向:大规模MIMO系统的信号检测。



扫码下载电子文档

版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所