

DOI:10.19651/j.cnki.emt.2208847

基于特征融合的风机叶片表面缺陷检测模型*

汤占军¹ 孙栋钦¹ 李英娜¹ 陆鹏²

(1.昆明理工大学信息工程与自动化学院 昆明 650000; 2.云南龙源风力发电有限公司 曲靖 655000)

摘要: 针对风机叶片表面缺陷检测识别率低、且易受光照影响的特点。提出一种基于卷积神经网络特征融合局部二值模式特征及核极限学习机的风机叶片表面缺陷检测方法。利用引入注意力机制的卷积神经网络提取图像深层次信息,然后提取描述图像浅层纹理信息的局部二值模式特征,采用主成分分析方法降低局部二值模式特征维度;将两种从不同层面描述图像的互补特征串行融合。用改进的麻雀搜索算法优化核极限学习机参数,利用融合的特征训练模型,得到最优模型进行缺陷识别。通过实验,在自建数据集训练后的分类准确率达到97.5%,kappa系数达到95.1。相比利用单一特征检测,分类准确率有明显的提高。经风电场实际验证,本模型的平均分类准确率为96.3%,Kappa系数为94.5,漏报率明显降低。

关键词: 图像处理;卷积神经网络;核极限学习机;麻雀搜索算法

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Defect detection model of wind turbine blade based on feature fusion

Tang Zhanjun¹ Sun Dongqin¹ Li Yingna¹ Lu Peng²

(1. College of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650000, China;

2. Yunnan Longyuan Wind Power Company Limited, Qujing 655000, China)

Abstract: In order to solve the problem of the wind turbine blade surface defect detection which has low detection recognition rate and can be easily affected by the light, this paper puts forward a wind turbine blade surface defect detection method based on convolutional neural network which combines local binary patterns with core extreme learning machine. The convolutional neural network introducing attention mechanism is used to extract deep information of images. Then, local binary patterns characteristics which can describe shallow texture information of images are also exacted. Besides, the principal component analysis can reduce local binary patterns characteristic dimension. Serial combination is then done to these two complementary characteristics which can describe images from different levels and the improved sparrow search algorithm is used to optimize Kernel extreme learning machine parameters. Besides, the syncretic feature training model is used to obtain the optimal model for defect recognition. The experiment shows that the classification accuracy rate after the training of self-built data sets can reach 97.5% and that the kappa coefficient can reach 95.1. Compared with single feature detection, the classification accuracy is significantly improved. The actual verification of the wind farm shows that the average classification accuracy of the model is 96.3%, the kappa coefficient is 94.5, and the missing rate is significantly reduced.

Keywords: image processing; convolutional neural network; nuclear limit learning machine; sparrow search algorithm

0 引言

近年来,风电作为清洁、可再生的能源在社会上受到了极大的关注,仅2020年度风电并网装机容量就达到了7 237万千瓦,在新能源中增长率最大。在风、电转化过程中,风机叶片扮演着捕获风能的重要角色。因长期承受风

力、旋转产生的不断变化的力,叶片可能会产生裂纹型缺陷。此外,叶片还会因为雨水、风沙的侵蚀产生腐蚀型缺陷。缺陷在形成之后,会随着时间推移逐渐扩大,影响发电效率,甚至发生叶片断裂等安全事故。为避免此类事件发生,风电场需要定期对风机叶片表面缺陷进行检测。传统检测采用人工高倍望远镜观察的方式,不仅效率低下,且漏

收稿日期:2022-01-13

* 基金项目:国家自然科学基金(61962031)项目资助

报率较高。有时还要停机观察和确认,严重影响了风机发电效益,因此利用人工智能技术提升检测的水平非常必要。

随着光学镜头分辨率的提升和计算机视觉技术的进步,无人机风电机组叶片巡检技术成为现在风电场常用的叶片检测手段,具有不产生二次损伤、不影响正常发电的优势。通过对无人机拍摄的图像进行处理、提取特征、最后分类或分割,达到检测的目的。曹锦纲等^[1]用改进的RPCA对得到的颜色特征、Gabor 特征进行低秩分解,得到缺陷的显著图,再进行分割实现缺陷的检测,但此研究不涉及到拍摄时叶片复杂的背景。张建斐^[2]在对风机叶片的图像进行处理之后,提取缺陷几何特征,对缺陷类型分类。仅用数字图像处理技术提取的特征单一,分类结果容易受到噪声,光照的影响,导致模型的泛化能力不强。由于卷积神经网络(convolutional neural networks, CNN)能够高效地提取图像深层特征,杨鹏^[3]提出深度残差网络与 SVM 分类器相结合的缺陷检测方法。张越^[4]使用 CNN 对风机图像进行缺陷分类,分类准确度在自建数据集下达到了 92.41%。与传统方法相比较,提升了不同背景下风机叶片的缺陷检测精度。基本的 CNN 对图像中各个位置都进行了相同的提取操作,但图像中不同部分需要的关注度是不同的,例如背景部分是不需要关注的。同时缺乏对图像纹理特征、局部细节的描述。由于小样本条件下 CNN 分类容易陷入局部最优,极限学习机(extreme learning machine, ELM)训练速度快^[5],精度高,用以代替 CNN 中的 softmax 函数。为

增强分类稳定性,在 ELM 的基础上引入核函数^[6],构建核极限学习机(kernel based extreme learning machine, KELM)。对麻雀搜索算法^[7]进行改进,优化 KELM 的参数。

基于上述问题,提出将两种特征融合后用 KELM 作分类器的风机叶片表面缺陷检测模型。在 CNN 中引入注意力机制^[8](convolutional block attention module, CBAM)对不同的空间、通道分配不同权重提升特征的质量。提取局部二值模式(local binary patterns, LBP)特征后采用主成分分析(PCA)减少特征冗余,降低维度。然后,将两种特征串行融合,输入 KELM 训练;同时利用改进的麻雀搜索算法(sparrow search algorithm, SSA)对 KELM 的参数寻优,提高分类精度。结果表明,相比提取单一特征做分类,用本方法提取特征能够降低光照不均带来的影响,优化后的 KELM 能提升分类准确率。

1 多特征提取及 KELM 分类

实际的生产中,风机叶片表面的常见缺陷主要是腐蚀和裂纹,本实验将无人机拍摄的图片分为裂纹、腐蚀和无缺陷三类。拍摄的图像中存在背景多样化、光照不均、缺陷占比小等问题。这是影响分类准确率的重要原因。

针对这些问题,提取两种特征从不同侧面描述图像,提高分类精度和鲁棒性。将 CNN 提取得到的特征与利用 PCA 降维后的 LBP 特征串行融合,然后将特征集作为输入,训练 KELM 分类器。算法的流程如图 1 所示。




图 1 算法基本流程

1.1 引入 CBAM 的 CNN 特征图像提取

CNN 由输入层、卷积层、池化层、全连接层和输出层构成,其典型结构如图 2 所示。卷积层中最重要的概念是卷积核,将输入和卷积核相乘得到的结果就是输入在这个特征上的投影。通过卷积、池化再经过激活函数作用得到特征图,层层卷积之后将图像凝练成特征向量。




图 2 CNN 典型结构

在 CNN 训练过程中,会产生大量的冗余特征。为了重点关注重要特征,引入了注意力机制。CBAM 能够在几乎不增加计算成本的情况下,通过赋予不同的权重提高特征的质量。CBAM 包含通道注意力机制和空间注意力机制^[9],结构如图 3 所示。




图 3 CBAM 的结构

图 4 是通道注意力机制操作流程,先对特征图进行最大池化和平均池化,输出两个相同维数的向量,将这两个向量分别输入同一个多层感知机中学习,将输出的结果逐个相加后送入 sigmoid 函数中激活得到通道注意力向量。权重向量计算公式如式(1),将这个向量与特征图的通道相乘就得到了加强通道注意力的特征图,如式(2):

$$M_c(F) = \sigma(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F))) = \sigma(W_1(W_0(F_{\text{avg}}^c)) + W_1(W_0(F_{\text{max}}^c))) \quad (1)$$

$$F' = M_c(F) \otimes F \quad (2)$$

F 为输入特征图, σ 是激活函数 sigmoid, $F_{\text{avg}}^c, F_{\text{max}}^c$ 分别表示全局平均池化和全局最大池化操作后的特征图,




图 4 通道注意力模块

W_1, W_0 是全连接层的权重, MLP 表示感知机, F' 为经通道注意力提炼的特征图, 得到的 $M_c(F)$ 为通道权重向量。

图 5 是空间注意力模块的具体操作, 对通道注意力机制输出的结果进行最大和平均池化操作。将这两个池化操作的结果拼接起来, 将拼接起来的特征图进行卷积操作, 得到的结果为空间注意力的权重矩阵, 计算方式如式(3)所示。沿通道方向广播后, 与特征图逐元素相乘得到加强空间注意力的特征图, 如式(4)所示。




图 5 空间注意力模块

$$M_s(F') = \sigma(f^{7 \times 7}([\text{AvgPool}(F'); \text{MaxPool}(F')])) = \sigma(f^{7 \times 7}([F'_{\text{avg}}; F'_{\text{max}}])) \quad (3)$$

$$F'' = M_s(F') \otimes F' \quad (4)$$

式中: $f^{7 \times 7}$ 是一个 7×7 的卷积核。 $F'_{\text{avg}}, F'_{\text{max}}$ 表示通道注意力向量再经过平均池化和全局最大池化操作后的结果 F'' 为经空间注意力提炼的特征图 $M_s(F')$ 为空间权重向量。

1.2 LBP 特征提取及降维

LBP^[10] 算子用于提取图像的局部纹理特征。将灰度图划分为若干区域, 分别建立 LBP 特征统计直方图, 直方图向量就是这幅图像的特征。本文采用 LBP 旋转不变模式, 使用圆形算子, 不断旋转圆形邻域, 取最小值为 LBP 值, 达到旋转不变性要求。

不同的特征从不同的侧面描述图像, 信息越多对分类越有利^[11], 本文融合两种图像特征。但融合后特征维度过大会导致后续的分类困难, 同时会存在冗余、无关的信息。为了降低计算复杂度, 采用 PCA^[12] 对 LBP 特征进行降维, 用较少的主成分表示特征。研究发现在贡献率为 0.95 时, 能够降低特征维度, 同时保证分类效果。

1.3 KELM 特征分类

ELM 在图像分类中已得到广泛应用^[13], 在训练的过程中, 需要设定的参数少、效率高且泛化性好^[14], 输出表示为:

$$f(x) = h(x)H^T(1/C + HH^T)^{-1}L \quad (5)$$

$f(x)$ 为目标函数, C 是正则化系数, x 为输入向量, $h(x)$ 、 H 为隐藏节点输出, L 为期望输出。Huang 引入核函数提高 ELM 的分类稳定性, 本文将径向基核函数 (rbf)

引入极限学习机之后, 式(5)就可以表达为:

$$f(x) = [K(x, x_1); \dots; K(x, x_n)](1/C + \Omega_{\text{ELM}})^{-1}L \quad (6)$$

$$\Omega_{\text{ELM}} = HH^T = h(x_i)h(x_j) = K(x_i, x_j) \quad (7)$$

式中: $K(x_i, x_j)$ 为径向基核函数, 定义如下:

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|}{\gamma^2}\right) \quad (8)$$

核参数 γ 反映数据样本的分布特性。

2 麻雀搜索算法及优化流程

2.1 麻雀搜索算法的改进

麻雀搜索算法将麻雀在自然界中的觅食和反捕食行为规律转化到优化算法中, 麻雀群体存在发现者和加入者两种角色, 并设立预警机制。发现者适应度高, 搜索范围广, 带领麻雀种群觅食。加入者跟随发现者进行觅食, 同时为提高自身捕食率, 加入者会监视发现者进行食物争夺或在其周围觅食。预警机制的作用是当种群面临捕食者威胁时, 会立即进行反捕食行为。发现者的更新公式为:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \exp\left(-\frac{i}{a \cdot T}\right) & R_2 < S \\ X_{i,j}^t + Q \cdot L & R_2 \geq S \end{cases} \quad (9)$$

$X_{i,j}^t$ 表示 t 代的第 i 个麻雀个体在第 j 维的信息, T 为最大迭代次数。 R_2 是警戒值; S 是安全值, 在警戒情况下麻雀向安全区方向靠近。 a 是 $[0, 1]$ 的随机值, Q 是随机值, 满足正态分布, L 是一个全 1 矩阵。加入者的更新公式:

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{\text{worst}} - X_{i,j}^t}{t^2}\right) & i > n/2 \\ X_P^{t+1} + |X_{i,j}^t - X_P^{t+1}| \cdot \Lambda^+ \cdot L & i \leq n/2 \end{cases} \quad (10)$$

X_P 代表最优的位置, A 表示全 1 或 -1 的矩阵, $A^+ = A^T(AA^T)^{-1}$, X_{worst} 代表最差的位置。麻雀种群中能够发出警报的个体占 20%, 面临危险时位置更新公式如下:

$$X_{i,j}^{t+1} = \begin{cases} X_{\text{best}}^t + \beta |X_{i,j}^t - X_{\text{best}}^t| & f_i > f_g \\ X_{i,j}^t + K \left[\frac{|X_{i,j}^t - X_{\text{worst}}^t|}{(f_i - f_w) + \epsilon} \right] & f_i = f_w \end{cases} \quad (11)$$

β 为随机数, 用于控制步长, K 是 -1 或 1, 控制方向。 f_i 代表适应值, f_g 和 f_w 为最好和最差适应值, ϵ 是一个常数。

麻雀搜索算法具有收敛速度快、更加稳定的特性。麻雀搜索算法对初始位置质量的要求较高, 且容易陷入局部最优。为提高麻雀算法的局部逃逸能力, 在更新公式中引入 Levy 飞行策略^[15], 特点是发生长程跳跃。但是在所有更新公式中加入 Levy 会极大的增加计算量, 因此只在搜索贡献大的发现者更新公式中引入 Levy 飞行策略。更新公式改进为:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \exp\left(-\frac{i}{a \cdot T}\right) + L(S), & R_2 < S \\ X_{i,j}^t + Q \cdot L + L(S), & R_2 \geq S \end{cases} \quad (12)$$

式中 Levy 函数如下:

$$\text{Levy}(S) = \frac{r_1 \times \sigma}{|r_2|^{1/\beta}} \quad (13)$$

式(13)中, r_1, r_2 为 $[0, 1]$ 范围内的随机数, β 的值取 1.5。 σ 的计算方式为:

$$\sigma = \left(\frac{\Gamma(1+\beta) \times \sin \frac{\pi\beta}{2}}{\Gamma((1+\beta)/2) \times \beta \times 2^{\frac{\beta-1}{2}}} \right)^{1/\beta} \quad (14)$$

式(14)中, $\Gamma(x) = (x-1)!$ 。

混沌具有遍历性、随机性和内在规律性。由于这几个特性,使用混沌映射随机生成种群初始位置有利于提高初始麻雀个体位置的质量。提高算法的全局搜索能力,达到优化的目的。本文利用 logistic 映射策略生成初始位置。其公式如下,其中 μ 为混沌系数:

$$x_{ij}(0) = (x_{ij} - lb) / (ub - lb) \quad (15)$$

$$x_{ij}(k+1) = \mu x_{ij}(k) (1 - x_{ij}(k)) \quad (16)$$

$$x_{ij} = lb + x_{ij}(k+1) \times (ub - lb) \quad (17)$$

式中: ub 和 lb , 代表麻雀位置范围 x_{ij} 的上限和下限。

2.2 KELM 的优化流程

为了获得最优的分类性能,用 ISSA 对 KELM 的正则化系数 C 、核参数 γ 进行寻优。具体的流程图如图 6。将 KELM 分类的准确率作为算法的适应度,不断更新麻雀个体的位置,由此找到最佳的适应度和相应的参数。用得到的最佳 KELM 模型对图像特征进行分类,实现风机叶片表面缺陷的检测。

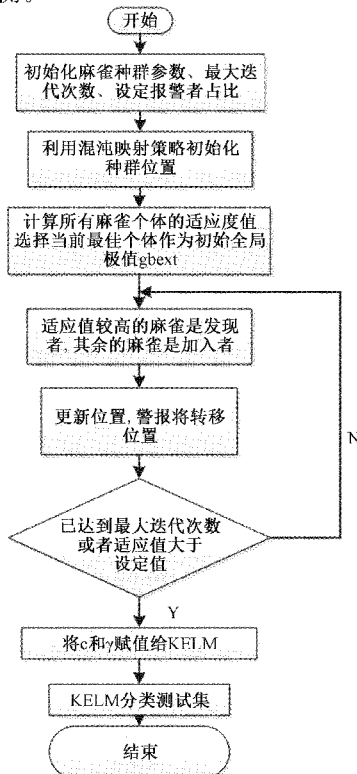


图 6 KELM 的优化过程

3 实验结果与分析

由大疆 M600PRO 无人机为机体加载工业相机,拍摄云南某风电场风机叶片。得到无缺陷的叶片图像 612 张,叶片裂纹图像和叶片腐蚀图像较少,经过平移、翻转、改变亮度等数字图像处理技术扩充数据集后,得到裂纹图像 452 张,腐蚀图像 478 张。将扩充后的图像集作为实验对象。训练集 1 314 张图像,训练集 228 张图像,其中无缺陷 81 张,裂纹 74 张,腐蚀 73 张。实验平台:处理器为 AMD Ryzen 7 4800H with Radeon Graphics 2.90 GHz, RAM 为 16.0 GB。运行环境包括 Matlab2018b、Python3.8、tensorflow2.2。

在经典卷积神经网络的基础上,引入注意力机制,根据数据集的实际情况,经过反复调试,确定了相关参数:学习率 0.000 01,防止过拟合权重衰减项为 0.000 5,学习率变化因子 0.1,模型迭代次数 200。输入的图像为 3 通道,图像大小调整为 100×100 。

在数据量很大时,模型越复杂、网络层数越多,分类效果越好,但在数据量较少时网络过于复杂往往导致分类性能较差。本文将综合考虑,经过实验后将 CNN 特征提取分为 3 个阶段,每段都由两个卷积层和一个最大池化层构成。通道数分别为 64, 128, 256, 最后全连接层的通道数为 256, 激活函数为 relu。为验证注意力机制所在的位置对特征提取效果的影响,使用 softmax 函数分类,通过分类结果判断提取的特征质量的优劣。实验表明,在 Pool3 之后引入注意力机制得到的特征质量较高。经过 CNN 特征提取后输出为 256 维的向量。提取 LBP 特征, LBP 圆形算子半径为 3, 领域设为 8, 得到 531 维向量。本实验选择 95% 贡献率下降维的 37 维特征。与 CNN 提取得到的 256 维特征串行融合, 得到 293 维的特征向量。

用得到的融合特征进行分类,麻雀搜索算法的基本设置如下:最大迭代次数 50,个体数 20,发现者和报警者的占比为 20% 和 10%,警戒值设为 0.8。为了检验模型性能,将本模型与 SVM 相比较,本模型表现出更好的分类性能。将准确率和 kappa 系数作为分类模型评价指标。计算公式如下:

$$k = \frac{p_0 - p_e}{1 - p_e} \quad (18)$$

p_0 为分类准确率。假设验证集中无缺陷、裂纹、腐蚀的个数为 a_1, a_2, a_3 , 预测结果每类个数为 b_1, b_2, b_3 , 总数是 N , 则:

$$p_e = \frac{a_1 \times b_1 + a_2 \times b_2 + a_3 \times b_3}{N \times N} \quad (19)$$

如表 1 所示,结合改进麻雀搜索算法的 KELM 模型和 SVM 模型准确率和 kappa 系数总是高于基本模型,证明改进的麻雀搜索算法能够提高模型分类性能。其中 ISSA-KELM 模型分类性能最好。

表 1 各方法分类的结果

分类模型	<i>Kappa</i> 系数	准确率%
KELM	0.921	95.6
SSA-KELM	0.934	96.8
ISSA-KELM	0.951	97.5
SVM	0.863	91.2
ISSA-SVM	0.885	92.9

模型训练中将无缺陷、裂纹、腐蚀三种类型标记为 0、1、2。图 7 是利用不同特征分类的结果。

分别建立了 CNN 特征分类模型, LBP 特征分类模型, CNN-LBP 特征分类模型。图 7 中(b) LBP 特征分类模型的结果显示, 相对较多地将无缺陷错分成裂纹图像。可能的原因是, 叶片本身存在弧度, 阳光照射下叶片形成阴面与阳面, 分界线与裂纹相似, 传统方法提取的特征不能很好的区分两者。图 7(a)、(c) 均用 CNN 提取图像特征明显减少了这一类的错分。




图 7 不同特征的分类结果

假设测试集的样本集合表示为 X , 在以 LBP 为特征条件下被分类正确的集合表示为 L_c , 在 CNN 提取的特征下被分类正确的集合表示为 F_c , 在两种条件下都被正确分类的样本记为 $L_c \cap F_c$ 。由于分类依赖的条件不同, 通常情况下分类的结果可以表示为图 8。




图 8 不同特征的分类结果

使用风电场最新拍摄得到的 373 张风机叶片图像, 对模型的性能进行验证。图像集中包括无缺陷类 203 张, 裂纹类 62 张, 腐蚀类 108 张。分类的结果如图 9 所示。




图 9 模型分类结果

经过多次实验, 模型的平均分类准确率为 96.3%, *Kappa* 系数为 94.5。说明了本模型的有效性。

4 结 论

针对风机叶片表面缺陷检测识别率低、易受光照影响的问题, 提出基于特征融合的检测模型。利用引入注意力机制的 CNN 提取无人机拍摄的风机叶片图像特征。将使用 PCA 方法降维后的 LBP 特征融合 CNN 提取的特征作为特征矢量。对麻雀搜索算法进行改进, 用于优化 KELM 参数, 以提高分类器的性能。对比实验表明, 两种特征弥补了相互的不足, 融合后的特征结合改进的分类方法能够提高缺陷检测能力, 对光照不均的问题有一定的改善。但风机叶片表面缺陷的识别率依然不高, 更合理的特征融合方式有待研究。

参考文献

- [1] 曹锦纲, 杨国田, 杨锡运. 基于 RPCA 和视觉显著性的风机叶片表面缺陷检测[J]. 图学学报, 2019, 40(4): 704-710.
- [2] 张建斐. 基于机器视觉的风力发电机叶片表面缺陷检测研究[D]. 兰州: 兰州理工大学, 2018.
- [3] 杨鹏. 基于无人机图像采集和改进深度残差网络分类算法的风机叶片表面缺陷检测系统研究[D]. 呼和浩特: 内蒙古工业大学, 2021, DOI: 10.27225/d.cnki.gnmgu.2021.000366.
- [4] 张越. 风力发电机叶片表面损伤图像识别方法研究[D]. 昆明: 昆明理工大学, 2019.
- [5] DUAN M X, LI K L, YANG C Q, et al. A hybrid deep learning CNN-ELM for age and gender classification[J]. Neurocomputing, 2018, 275, DOI: 10.1016/j.neucom.2017.08.062.

- [6] WANG J, SONG Y F, MA T L. Mexican hat wavelet kernel ELM for multiclass classification [J]. Computational Intelligence and Neuroscience, 2017, DOI: 10.1155/2017/7479140.
- [7] 薛建凯. 一种新型的群智能优化技术的研究与应用[D]. 上海: 东华大学, 2020.
- [8] SANGHYUN W, JONGCHAN P, JOON-Y L, et al. CBAM: Convolutional block attention module [J]. ECCV 2018; Computer Vision-ECCV 2018, 11211: 3-19, DOI: 10.1007/978-3-030-01234-2_1.
- [9] CAO W, FENG Z, ZHANG D, et al. Facial expression recognition via a CBAM embedded network [J]. Procedia Computer Science, 2020, 174, DOI: 10.1016/j.procs.2020.06.115.
- [10] AHONEN T, HADID A, PIETIKÄINEN M. Face description with local binary patterns: application to face recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28 (12), DOI: 10.1109/TPAMI.2006.244.
- [11] 王军, 何昕, 魏仲慧, 等. 基于多特征匹配的快速星图识别算法 [J]. 光学精密工程, 2019, 27(8): 1870-1879.
- [12] 吴婷, 尚宇. 基于 Android 平台人证合一技术的研究 [J]. 国外电子测量技术, 2020, 39(5): 86-89, DOI: 10.19652/j.cnki.femt.1901917.
- [13] 王鹏, 张肖敏, 白艳萍. 基于 CNN-ELM 的 SAR 图像分类识别 [J]. 数学的实践与认识, 2018, 48(23): 75-80.
- [14] 张淑清, 要俊波, 张立国, 等. 基于改进深度稀疏自编码器及 FOA-ELM 的电力负荷预测 [J]. 仪器仪表学报, 2020, 41(4): 49-57.
- [15] 唐朝国. 基于改进 Levy 飞行的 PSO 湿度传感器补偿算法 [J]. 电子测量与仪器学报, 2020, 34(3): 119-125.

作者简介

汤占军(通信作者), 博士, 高级工程师, 主要研究方向为新能源发电、智能控制。

E-mail: 47605055@qq.com

孙栋钦, 硕士研究生, 主要研究方向为风力发电、图像处理与识别。

E-mail: 2112054408@qq.com

李英娜, 博士, 教授, 主要研究方向为传感网组建与信息集成和智能分析研究。

E-mail: 84077971@qq.com

陆鹏, 硕士, 中级工程师, 主要研究方向为风电场数据分析。

E-mail: 511235627@qq.com