

人工鱼群算法和支持向量机的建筑电气故障识别

为了提高建筑电气故障的识别效率,提出一种人工鱼群算法和支持向量机相融合的建筑电气故障识别模型。首先采集建筑电气状态信息并提取特征,对特征向量进行归一化处理;然后采用人工鱼群算法模拟鱼群觅食和追尾行为找到最优特征子集,减少分类器的输入维数;最后采用支持向量机建立建筑电气故障识别模型,并对模型性能进行了仿真测试。仿真结果表明,相对于建筑电气故障识别模型,该模型提高了建筑电气故障识别率,减少了模型训练时间,可以满足建筑电气故障识别的工程应用需求。

李 忠/重庆电子工程职业学院物联网学院



李 忠/高级实验师

随着现代科学技术的进步,一座座高楼拔地而起,高层建筑对电气的可靠性要求日益提高,导致建筑电气系统越来越复杂^[1]。建筑电气故障准确识别是保证建筑电气可靠性的一种关键技术,建筑电气系统一旦发生故障,轻者导致停电,影响人们正常的工作和生活;重者会产生灾难性后果。因此对建筑电气故障进行建模与识别,有效提高建筑电气系统的可靠性和安全性,是目前急需解决的难题之一^[2]。

为了保证建筑电气系统稳定、正常工作,应提高建筑的安全性和舒适度,本文提出一种人工鱼群算法(Artificial Fish Swarm Algorithm, AFSA)^[3]和支持向量机(Support Vector Machine, SVM)^[4]的建筑电气故障识别模型(AFSA-SVM)。该模型首先采用人工鱼群算法选择建筑电气故障的最优特征子集,然后采用支持向量机构建建筑电气故障识别分类器,最后进行仿真实验。仿真实验结果表明,AFSA-SVM

可以准确、快速地识别出建筑电气故障类别,提高建筑电气系统故障识别的效率,同时满足建筑电气故障识别的工程应用需求,保障建筑电气系统的安全运行。

相关研究

建筑电气故障识别具有重要的经济效益,因此国内外众多学者投身其研究中,当前建筑电气故障识别技术可以分为三个阶段:人工阶段、专家系统阶段和智能识别阶段^[5]。人工阶段起始于19世纪90年代,主要凭经验或简单仪器进行建筑电气故障识别,识别结果好坏与技术人员自身知识直接相关,识别结果主观性比较强,有一定的盲目性,不能满足现代建筑电气系统故障识别的实际要求^[6];专家系统阶段主要为计算机与传感器结合的阶段,如状态空间分析识别技术等,通过传感器采集各种识别信号,然后利用计算机进行数据处理,识别效率明显提高,但是其没有自学习能力,自适应能力也差^[7];近年来,随着人工智能研究的不断深入,建筑电气故障识别进入到一个全新阶段,涌现出许多基于神经网络的建筑电气故障识别模型,识别结果的可靠性和准确性大幅度提高^[8-10],然而神经网络要求训练样本数量大,而且存在一些自身难以克服的缺陷(如收敛速度慢、过拟合等),在实际应用中,每一类故障对应各自最适合的特征,因此特征子集的选择对故障结果优劣至关重要^[11]。

关键词/Keywords

建模电气·
故障识别·
支持向量机·
特征选择·
人工鱼群算法·

AFSA-SVM的建筑电气故障识别模型

1. 工作原理

AFSA-SVM的建筑电气故障识别原理为：首先采集建筑电气故障状态下的输出信号，并从中提取特征；然后采用人工鱼群算法选择建筑电气故障最优特征子集；最后采用支持向量机构建建筑电气故障识别分类器，从而准确、快速地识别出建筑电气故障类别。AFSA-SVM的建筑电气故障识别原理如图1所示。




图1 AFSA-SVM的建筑电气故障识别原理

2. 人工鱼群算法

人工鱼群算法是一种模拟鱼群觅食与追尾行为的群智能算法，搜索具有并行性、自适应能力，较好地克服了其他算法陷入局部极值的难题。

(1) 鱼群的觅食行为

设 X_i 为鱼群的当前状态； X_j 为鱼群视野范围内的一个状态。如果 $X_i < X_j$ ，那么鱼群向 X_j 前进一步；否则重新随机选择一状态 X_j ，并进行相应判断。如果仍然不能满足 $X_i < X_j$ 的条件，那么就随机前进一步，鱼群的觅食行为具体方式可以描述为

$$\begin{cases} X_{i\text{next}} = X_i + \text{rand}() \cdot \text{step} \cdot \frac{X_j - X_i}{\|X_j - X_i\|} & Y_i < Y_j \\ X_{i\text{next}} = X_i + \text{rand}() \cdot \text{step} & \text{其他} \end{cases} \quad (1)$$

式中， $\text{rand}()$ 为在(0,1)内的随机数； step 为前进的步长。

(2) 鱼群的聚群行为

设 n_f 为鱼群视野范围内的同伴数； X_c 为邻域内伙伴的中心位置； δ 为拥挤度因子。如果 $X_i/n_f > \delta X_c$ ，则表示该鱼群的中心食物较多并且拥挤，因此鱼群向中心位置前进一步；否则就执行其他行为，鱼群的聚群行为可以描述为

$$X_{i\text{next}} = X_i + \text{rand}() \cdot \text{step} \cdot \frac{X_c - X_i}{\|X_c - X_i\|} \quad (2)$$

(3) 鱼群的追尾行为

设 X_j 为鱼群视野范围内的食物密度最大位置。如果 $X_j/n_f > X_i\delta$ ，则表明 X_j 周围食物密度较高且不拥挤，朝 X_j 前进一步；否则执行觅食行为，鱼群的追尾行为具体可以表示为

$$X_{i\text{next}} = X_i + \text{rand}() \cdot \text{step} \cdot \frac{X_j - X_i}{\|X_j - X_i\|} \quad (3)$$

3. 提取电气故障特征

建筑电气故障类型可分为线路阻抗故障(E_1)、连续性故障(E_2)、接地电阻异常(E_3)及绝缘电阻过小(E_4)四种，再加上正常状态(E_5)，故障数据通过提取10个不同位置的电阻值作为建筑电气故障的原始特征，详细步骤见文献[12]。

4. 最优特征选择的数学模型

对于不同类别的建筑电气故障，其相应的最优特征子集也不相同，如果将全部建筑电气特征输入到分类器中进行建模，将会导致计算复杂度高、学习效率低，而且一些该类建筑电气故障识别的特征会对故障识别结果产生不利影响，因此，本文采用人工鱼群算法对建筑电气故障进行选择，找到最优特征子集，同时采用二进制对建筑电气故障特征进行编码，即有 $S = \{s_1, s_2, \dots, s_n\}$ ， $s_i \in \{0, 1\}$ 。“1”表示该特征被选中，“0”表示该特征不被选中，那么建筑电气故障的特征选择数学模型具体如下

$$\begin{aligned} & \max_S G(S) \\ & \text{s. t.} \\ & \begin{cases} S = \{s_1, s_2, \dots, s_n\} \\ s_i \in \{0, 1\} \\ i = 1, 2, \dots, n \end{cases} \end{aligned} \quad (4)$$

5. 人工鱼群算法选择的步骤

人工鱼群位置的好坏由食物密度来衡量，这是建筑电气故障特征子集优劣的评价准则。由于故障识别正确率和特征个数是两个评价因子，特征数应该尽可能少，而故障识别正确率应尽可能高，因此食物密度的评价标准定义为

$$FC = P_{svm} \times 100 + \alpha \frac{d}{L} \quad (5)$$

式中, P_{svm} 为故障识别正确率; L 为建筑电气故障的原始特征数; d 为选择的特征数; α 为权重。

采用人工鱼群算法选择的步骤如下:

- 1) 设置人工鱼群算法的参数, 如拥挤度因子为 δ 、移动步长 $step$ 等, 并初始化人工鱼群。
- 2) 在公告板记录最优人工鱼个体状态及该人工鱼位置的食物密度值。
- 3) 每条人工鱼分别模拟鱼群的追尾、聚群和觅食行为。
- 4) 每条人工鱼在行动一次后与公告板进行比较, 若优于公告板, 则用自身状态取代公告板状态。
- 5) 如果达到终止条件, 则执行步骤6); 否则返回步骤2) 继续。
- 6) 根据公告板记录的最优人工鱼位置得到建筑电气故障识别的最优特征子集。

建立建筑电气故障识别器

支持向量机解决了人工神经网络等方法存在的陷入局部最优解的难题。设训练样本集为 $\{(x_i, y_i), i = 1, 2, \dots, N\}$, N 为样本数量, 支持向量机的分类函数为

$$f(x) = \omega f(x) + b \quad (6)$$

式中, ω 为维向量; b 为阈值。

采用最小化结构来确定 ω 和 b , 即可以得到

$$\min R_{str} = \frac{1}{2} \|\omega\|^2 + CR_{emp} \quad (7)$$

其中

$$R_{emp} = \frac{1}{N} \sum_{i=1}^N L_{\varepsilon}(x_i, y_i - f(x_i)) \quad (8)$$

$$L_{\varepsilon}(x, y - f(x)) = \max\{0, |y - f(x) - \varepsilon|\} \quad (9)$$

式中, C 为权重系数。

引入Lagrange乘子 α_i 和 α_i^* , 得到原始问题的对偶问题为

$$\begin{aligned} \min & \frac{1}{2} \sum_{i,j=1}^l (\alpha_i^* - \alpha_i)(\alpha_j^* - \alpha_j) K(x_i, x_j) + \\ & \varepsilon \sum_{i=1}^l (\alpha_i^* + \alpha_i) - \sum_{i=1}^l y_i (\alpha_i^* - \alpha_i) \end{aligned} \quad (10)$$

s. t.

$$\sum_{i=1}^l (\alpha_i^* - \alpha_i) = 0 \quad 0 \leq \alpha_i^*, \alpha_i \leq C (i = 1, 2, \dots, l)$$

最后支持向量机的分类判别函数为

$$f(x) = \text{sgn} \left(\sum_{i=1}^l (\alpha_i^* - \alpha_i) K(x_i, x) + b \right) \quad (11)$$

式中, $K(x_i, x)$ 为满足Mercer条件的核函数。

支持向量机是二分类器, 而建筑电气故障识别是一种多分类问题, 因此必须构造多分类器才能进行建筑电气故障的自动识别, 本文采用“一对多”的分类器结构, 具体如图2所示。




图2 多分类的支持向量机

AFSA-SVM在建筑电气故障识别中的应用

1. 数据源

为了测试AFSA-SVM在建筑电气故障识别的效果, 采用Matlab 2012工具箱编程实现AFSA-SVM的仿真测试。通过实验平台实测收集了100个样本, 每个样本含10个不同位置的故障信息特征分量, 选择前80个样本进行训练, 建立基于AFSA-SVM的建筑电气故障识别模型, 剩余20个样本作为测试样本, 检测AFSA-SVM的泛化推广能力。样本具体如表1所示。

表1 收集的样本数据

状态	训练样本数	测试样本数
E ₁	15	5
E ₂	12	8
E ₃	15	5
E ₄	16	4
E ₅	15	5

将没有特征选择的支持向量机(SVM)和人工鱼群算法选择特征+RBF神经网络的建筑电气故障识别模型(AFSA-RBF)进行对照实验。

由于样本中建筑电气故障特征单位不同，为了降低计算复杂度，避免特征之间的相互影响，需对特征进行归一化处理，即

$$y_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (12)$$

式中， $x_{\max}$ 为最大值； $x_{\min}$ 为最小值。

2. 支持向量机核函数的选择

在支持向量机构建建筑电气故障分类器的过程中，核函数的选择十分重要，当前核函数主要有如下几种：

1) 线性核函数

$$K(x_i, x) = x_i x \quad (13)$$

2) 多项式核函数

$$K(x_i, x) = (x_i x + 1)^d \quad (14)$$

3) Sigmoid核函数

$$K(x_i, x) = \tanh(b x_i^T x + \theta) \quad (15)$$

4) RBF核函数

$$K(x_i, x) = \exp\left(-\frac{\|x_i - x\|^2}{2\sigma^2}\right) \quad (16)$$

为了测试不同核函数构建的支持向量机性能，将构建的建筑电气状态划分为正常和故障两类（所有故障类别归为一类），其识别率如表2所示。从表2可知，基于RBF核函数的支持向量机分类性能最优，建筑电气故障识别率最高，因此本文选择RBF核函数建立建筑电气故障识别模型。

表2 不同核函数支持向量机的性能对比

核函数类别	故障识别率
线性核函数	15
多项式核函数	15
Sigmoid核函数	16
RBF核函数	12

3. 结果与分析

(1) 识别结果比较

首先采用人工鱼群算法确定各种类别故障的最优特征子集；然后采用5折交叉验证算法确定支持向量机参数 C 、 σ ，从而构建建筑电气故障识别模型。所有模型都执行5次仿真实验，AFSA-SVM与对比模型的平均识别率如图3所示。从图3可知，AFSA-SVM的建筑电气故障识别率最高，

而且有如下结论：

1) 相对于SVM，AFSA-SVM的建筑电气故障识别率得到了大幅度提升，主要是因为AFSA-SVM采用了人工鱼群算法对建筑电气特征子集进行选择，消除了对识别结果不利或者影响较小的特征，建立了更优的建筑电气故障识别模型，获得了更加理想的建筑电气故障识别结果。

2) 相对于AFSA-RBF，AFSA-SVM提高了建筑电气故障的识别率，这主要是由于AFSA-SVM采用了支持向量机设计的建筑电气故障分类器，具有非线性、自适应学习能力更强的特点，可以更加准确地找到特征向量与建筑电气故障类别之间的联系，克服了神经网络的过拟合、泛化能力差等不足，建立了更优的建筑电气故障分类器，降低了建筑电气故障的误识率。




图3 AFSA-SVM与其他模型的故障识别率比较

(2) 故障建模时间对比

在实际应用中，建筑电气故障识别速度也至关重要，采用平均训练时间作为建模时间评价准则，AFSA-SVM与其他模型的平均训练时间如图4所示。从图4可以看出，AFSA-SVM的平均训练时间最少，主要是由于AFSA-SVM通过人工鱼群算法选择了最优的特征子集，减少了分类器的输入向量数，计算复杂度下降；同时由于建筑电气




图4 AFSA-SVM与其他模型的训练时间对比

故障识别是一种小样本分类问题,支持向量机是针对小样本、高维分类的机器学习算法,克服了神经网络收敛速度慢等不足,加快了训练速度,拓宽了模型的应用范围。

结束语

为了提高建筑电气故障的识别效果,提出一种人工鱼群算法和支持向量机相融合的建筑电气故障的识别模型。仿真实验表明,相对于其他建筑电气故障识别模型,本文模型提高了建筑电气故障的识别率,并且故障识别模型的训练速度得到了提升,可以满足建筑电气故障识别的工程应用需求,具有广泛的应用前景。

参考文献

- [1] 贺湘琨.从两起事故看“电楼”现象[J].建筑电气,2011,30(2):3-5.
- [2] 王宏力,侯青剑.故障识别方法现状与展望[J].传感器与微系统,2008,27(5):1-4.
- [3] 陈安华,周博,张会福,等.基于改进人工鱼群算法的机械故障聚类诊断方法[J].振动与冲击,2012,31(17):145-200.
- [4] 胡国胜.支持向量机及在电力系统中的应用[J].高电压技术,2007,33(4):101-105.
- [5] 邵晓非,宁媛,刘耀文,等.电力系统故障识别方法综述与展望[J].工业控制计算机,2012,25(12):4-7.
- [6] 杜伟康.浅谈电气线路常见故障的分析与处理[J].城市建设理论研究,2013(2):56-58.
- [7] 王焕,王亚慧.建筑电气实验平台的故障自识别算法研究[J].北京建筑工程学院学报,2010,26(4):100-105.
- [8] 范庚,马登武,张继军,等.基于决策树和相关向量机的智能故障识别方法[J].计算机工程与应用,2013,49(14):267-270.
- [9] 霍一峰.基于神经网络的建筑电气故障识别研究[D].北京:北京建筑工程学院,2012.
- [10] 吴茜,王亚慧.基于RBF与BP神经网络的建筑电气系统故障识别比较研究[J].北京建筑工程学院学报,2012,28(4):92-96.
- [11] 王亚慧,张龙,韩宁.建筑电气系统故障识别方法研究[J].计算机仿真,2014,31(2):436-440.
- [12] 张龙,陈宸,韩宁,等.基于压缩感知理论的建筑电气系统故障识别[J].智能系统学报,2014,9(2):377-380.

(收稿日期:2015-04-12) EA

(上接第88页)

参考文献

- [1] 郭蕾.接触网覆冰机理与在线防冰方法的研究[D].成都:西南交通大学,2013.
- [2] 郭蕾,李群湛,解绍锋.在线防冰过程中电气化铁路接触网的温度场[J].西南交通大学学报,2013(2):230-235,242.
- [3] 李群湛,郭蕾,舒泽亮.电气化铁路接触网在线防冰技术研究[J].铁道学报,2013(10):46-51.
- [4] 崔永强.电气化铁路接触网在线防冰技术方案研究[D].成都:西南交通大学,2013.
- [5] 孙轩.电气化铁路接触网防冰融冰技术研究[D].成都:西南交通大学,2012.
- [6] 李岗,郭华.接触网交流在线防冰与离线融冰原理研究[J].电气化铁道,2012(6):5-8.
- [7] 王国梁.接触网融冰防冰问题的分析研究[J].铁道工程学报,2009(8):93-95.
- [8] 莫理莉,甘凌霄,王善生.输电线路完善化融冰技术综述[J].电气自动化,2013(3):1-3,18.
- [9] 敬华兵,年晓红.电气化铁路接触网直流融冰技术及装置研制[J].电工技术学报,2012(9):277-284.
- [10] 王猛.AT所全并联供电方式牵引网电压损失分析[C].电气化铁路牵引变电所新技术研讨会论文集,2004.

(收稿日期:2015-03-14) EA