

1-3-2019

## Prediction Model for Breakdown Voltage of Transformer Oil Based on Relative Transformation and Kernel Principal Component Analysis

Yinguo Xiong

*School of Physical Science and Engineering, Yichun University, Yichun 336000, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research, Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

# Prediction Model for Breakdown Voltage of Transformer Oil Based on Relative Transformation and Kernel Principal Component Analysis

## Abstract

**Abstract:** Aiming at the difficulty of measuring the breakdown voltage of transformer oil on line, a new prediction model for breakdown voltage of transformer oil is proposed based on relative transformation (RT) and kernel principal component analysis (KPCA). By analyzing the factors that are closely related to the breakdown voltage, the original data space is converted to the relative data space by relative transformation to improve the distinguishability between data. KPCA is employed in the relative space for the purpose of data dimension reduction, denoising and extracting nonlinear features. Kernel principal components extracted by KPCA are used as the input of kernel extreme learning machine (KELM) to establish the prediction model for breakdown voltage of transformer oil, and the parameters of prediction model are optimized by differential evolution algorithm. Compared with RTKPCA-LSSVM, RTPCA-KELM and RTPCA-LSSVM, the simulation results illustrate that the proposed prediction method has better prediction precision and generalization ability.

## Keywords

breakdown voltage, relative transformation, kernel principal component analysis, kernel extreme learning machine, differential evolution algorithm

## Recommended Citation

Xiong Yinguo. Prediction Model for Breakdown Voltage of Transformer Oil Based on Relative Transformation and Kernel Principal Component Analysis[J]. Journal of System Simulation, 2018, 30(5): 1657-1664.

# 相对变换 KPCA 的变压器油击穿电压预测建模

熊印国

(宜春学院物理科学与工程技术学院, 江西 宜春 336000)

**摘要:** 针对变压器油击穿电压的在线测量问题, 提出基于相对变换(RT)核主元分析(KPCA)的变压器油击穿电压预测建模方法。分析与击穿电压关联密切的因素, 通过相对变换将原始数据空间变换到相对空间, 提高数据之间的可区分性; 利用 KPCA 对相对空间进行特征提取, 达到降低数据维数、滤除数据噪声、提取数据非线性特征的目的; 将 KPCA 提取的主元变量作为核极限学习机(KELM)的输入, 建立变压器油击穿电压预测模型并采用差分进化算法优化模型参数。与 RTKPCA 最小二乘支持向量机(LSSVM)、RTPCA-KELM 和 RTPCA-LSSVM 方法进行比较, 实验结果表明所提出的方法具有良好的预测精度和泛化能力。

**关键词:** 击穿电压; 相对变换; 核主元分析; 核极限学习机; 差分进化

中图分类号: TP183

文献标识码: A

文章编号: 1004-731X (2018) 05-1657-08

DOI: 10.16182/j.issn1004731x.joss.201805005

## Prediction Model for Breakdown Voltage of Transformer Oil Based on Relative Transformation and Kernel Principal Component Analysis

Xiong Yinguo

(School of Physical Science and Engineering, Yichun University, Yichun 336000, China)

**Abstract:** Aiming at the difficulty of measuring the breakdown voltage of transformer oil on line, a new prediction model for breakdown voltage of transformer oil is proposed based on relative transformation (RT) and kernel principal component analysis (KPCA). By analyzing the factors that are closely related to the breakdown voltage, the original data space is converted to the relative data space by relative transformation to improve the distinguishability between data. KPCA is employed in the relative space for the purpose of data dimension reduction, denoising and extracting nonlinear features. Kernel principal components extracted by KPCA are used as the input of kernel extreme learning machine (KELM) to establish the prediction model for breakdown voltage of transformer oil, and the parameters of prediction model are optimized by differential evolution algorithm. Compared with RTKPCA-LSSVM, RTPCA-KELM and RTPCA-LSSVM, the simulation results illustrate that the proposed prediction method has better prediction precision and generalization ability.

**Keywords:** breakdown voltage; relative transformation; kernel principal component analysis; kernel extreme learning machine; differential evolution algorithm

### 引言

电力变压器的内绝缘通常为油纸绝缘结构, 变



收稿日期: 2016-06-01 修回日期: 2016-08-12;

基金项目: 国家自然科学基金(51366013);

作者简介: 熊印国(1974-), 男, 江西丰城, 硕士, 讲师, 研究方向为复杂工业过程建模, 故障诊断等。

压器油作为主要的绝缘介质, 在长期的电应力、热应力、氧化等多种因素作用下发生氧化、裂解与碳化等反应, 影响变压器油的绝缘性能进而危及变压器的安全运行。因此, 准确评估变压器油的绝缘状态, 对于实现变压器的状态检修有着重要的意义<sup>[1]</sup>。击穿电压集中体现了变压器油的绝缘品质, 由于测量手段的局限性, 难以实现击穿电压的

<http://www.china-simulation.com>

• 1657 •

在线检测,并且击穿实验为破坏性实验,往往破坏性实验是不经济的也是不可取的。因此,检测变压器油日常监测参量,通过建立击穿电压的软测量模型来进行预测,是一种有效的替代手段和方法。

变压器油击穿电压的预测多采用神经网络和支持向量机(support vector machine, SVM)建模。文献[2]在分析击穿电压与变压器油日常监测参量的关联性基础上,利用BP神经网络强大的非线性映射能力,建立了击穿电压的神经网络预测模型。然而,BP神经网络建模存在训练难收敛、模型结构难确定、易陷入局部极值等问题。支持向量机建立在结构风险最小化原理的基础上,克服了神经网络的以上缺点,在复杂工业过程建模中得到广泛应用<sup>[3]</sup>。然而,由于普遍存在的数据噪音,导致SVM算法产生性能偏差,影响SVM的泛化能力。相对变换<sup>[4-5]</sup>(relative transformation, RT)是一种基于人类认知相对性的数据分析方法,它考虑了所有数据点的影响,通过相对变换使噪声和孤立点远离正常点,有效地抑制噪声和孤立点对机器学习性能的影响。文献[5]提出了相对变换的SVM分类方法,通过实验验证了相对变换具有抑制噪声和孤立点对机器学习性能的影响。然而,相对变换在数据规模较大时构造出的相对空间维数高,导致出现维数灾难问题。主元分析<sup>[6-7]</sup>(principal component analysis, PCA)是一种线性的数据降维方法,它采用数据投影的方式,以少量主元变量来表征原始数据的绝大部分信息。相对变换是非线性放大变换,可提高数据的可区分性,同时还能抑制噪声从而提高机器学习性能,PCA能有效提取数据特征并实现降维,有利于机器学习。结合两者的优势,文献[6]提出了相对变换主元分析的故障检测方法;文献[7]提出了基于相对变换主元分析的变压器油击穿电压预测建模方法,该文用相对变换主元分析提取更具有变异性和代表性的相对主元,用最小二乘支持向量机(least squares SVM, LSSVM)建模,取得了较好的预测效果。但是,相对变换为非线性变换而PCA是线性的特征提取方法,利用PCA去处理和

分析相对空间,提取的数据特征会丢失部分信息。核主元分析<sup>[8-9]</sup>(kernel PCA, KPCA)采用核技巧通过非线性映射将原始数据空间变换到特征空间,然后在特征空间中进行主元分析,在实现降维的同时,能够有效地提取数据的非线性特征、滤除数据噪声、消除变量间的相关性。

极限学习机<sup>[10]</sup>(extreme learning machine, ELM)是一种新型的单隐层前馈神经网络,它有效克服了基于梯度学习算法的神经网络缺陷,具有良好的泛化能力和极快的学习速度,并已成功应用于复杂系统建模、模式识别等领域<sup>[11-12]</sup>。但是,随机选取隐含层参数造成ELM学习性能不稳定,针对这一问题,文献[13-14]将核函数引入ELM,提出核极限学习机(kernel extreme learning machine, KELM),提高了解决预测回归问题的能力。

因此,本文提出了基于相对变换核主元分析(relative transformation kernel principal component analysis, RTKPCA)的变压器油击穿电压预测建模方法。用相对变换将输入数据空间变换到相对空间,在相对空间中利用KPCA进行特征提取,以提取的主元作为KELM的输入,建立击穿电压的KELM预测模型。由于KPCA特征提取效果和KELM的学习和泛化能力很大程度上取决于其参数的合理选择,而KPCA和KELM参数的优化过程是相互依赖、相互制约的,为使本文提出的预测模型整体性能最优,应同时优化。以预测精度为目标,本文提出差分进化<sup>[15-17]</sup>(differential evolution, DE)算法的KPCA和KELM参数组合优化方法。最后,通过实验仿真表明相对变换核主元分析的变压器油击穿电压建模的有效性。

## 1 RTKPCA的特征提取

### 1.1 相对变换

在原始数据空间中,以每个样本为基向量,任意点的坐标为该点到所有点的距离,即为相对变换,有:

$$\Gamma: X \rightarrow Z \subset R^n$$

$$\Gamma_X(x_i) = (d_{i1}, d_{i2}, \dots, d_{in}) \in Z \quad (1)$$

式中:  $X = \{x_1, x_2, \dots, x_n\}$ ,  $x_i \in R^m$ ;  $n$  为样本数;  $m$  为变量数;  $d_{in}$  为点  $x_i$  到点  $x_n$  距离, 常用欧式距离计算。

相对变换具有非线性放大作用, 可提高数据间的可区分性。同时它考虑所有数据点的影响, 使噪音和孤立点远离正常点, 提高数据分析的准确性<sup>[5]</sup>。

## 1.2 核主元分析

KPCA 的基本思想是将输入空间  $X_{n \times m}$  通过非线性映射  $\phi$  映射到特征空间  $F$ , 然后在高维特征空间进行主元分析, 映射数据  $\phi(x_i)$  的协方差矩阵表示为

$$C^F = \frac{1}{n} \sum_{i=1}^n \phi(x_i) \phi^T(x_i) \quad (2)$$

$$\text{求解特征值问题: } \lambda v = C^F v \quad (3)$$

$C^F$  的特征矢量  $v$  可表示为

$$v = \sum_{i=1}^n a_i \phi(x_i) \quad (4)$$

引入核矩阵  $K$ :  $K_{ij} = \langle \phi(x_i), \phi(x_j) \rangle$ , 其中,  $\langle \phi(x_i), \phi(x_j) \rangle$  为  $\phi(x_i)$  和  $\phi(x_j)$  的点积, 式(3)可写为

$$n\lambda a = Ka \quad (5)$$

通过计算映射数据在特征矢量  $v_k$  上的投影来计算主元, 即

$$t_k = \langle v_k, \phi(x) \rangle = \sum_{i=1}^n a_i^k \langle \phi(x_i), \phi(x) \rangle \quad (6)$$

式中:  $k$  为主元数, 主元数依据累积方差贡献率大于 85% 来选取。KPCA 的基本原理可参考文献[8]。

核函数通常选取高斯径向基函数

$$K(x_i, x_j) = \exp(-\|x_i - x_j\|^2 / r) \quad (7)$$

式中:  $r$  为核参数。

## 1.3 RTKPCA 特征提取算法

相对变换能够有效抑制噪声或识别孤立点, 同时还具有非线性放大作用, 但构造的相对空间维数较高; 核主元分析能够有效地提取数据的非线性特

征、降低数据维数。因此, 利用 KPCA 对相对空间进行分析, 数据分析的准确性应比 PCA 要高。

RTKPCA 特征提取算法的主要步骤如下:

Step 1: 输入训练样本集  $X \in R^{n \times m}$ , 按公式(8)标准化;

$$\bar{X} = \left( X - \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} \begin{bmatrix} \mu_1 & \dots & \mu_m \end{bmatrix} \right) \begin{bmatrix} \sigma_1^{-1} & & & \\ & \sigma_2^{-1} & & \\ & & \ddots & \\ & & & \sigma_m^{-1} \end{bmatrix} \quad (8)$$

式中:  $\sigma_i$ ,  $\mu_i$  为第  $i$  个变量的标准差和均值。

Step 2: 由公式(1)对  $\bar{X}$  进行相对变换, 得到相对空间矩阵  $X^R \in R^{n \times n}$ ;

Step 3: 按公式(7)计算  $X^R$  的核矩阵  $K$ , 并按公式(9)中心化;

$$\bar{K} = K - KE_n - E_n K + E_n KE_n \quad (9)$$

式中:  $E_n$  为各项元素为  $1/n$  的  $n \times n$  方阵;

Step 4: 求解公式(5)的特征值问题, 依据累积方差贡献率大于 85% 选取主元数;

Step 5: 按公式(6)计算训练样本的主元集  $t$ ;

Step 6: 输入测试样本集  $X_t \in R^{n_t \times m}$ , 按公式(8)标准化后, 再按公式(1)相对变换后得到矩阵  $X_t^R \in R^{n_t \times n}$ ;

Step 7: 按公式(7)计算  $X_t^R$  的核矩阵  $K_t \in R^{n_t \times n}$ , 并按公式(10)中心化;

$$\bar{K}_t = K_t - E_{n_t} K - K_t E_n + E_{n_t} K E_n \quad (10)$$

式中:  $E_{n_t}$  为各项元素为  $1/n_t$  的  $n_t \times n$  矩阵;

Step 8: 按公式(6)计算测试样本的主元集  $t_t$ 。

## 2 核极限学习机

极限学习机是由 Huang 等<sup>[10]</sup>依据广义逆矩阵理论提出的一种新型单隐层前馈神经网络算法, 仅一步计算即可解析求出网络的输出权值, 且具有不高于 SVM 的泛化能力和学习速度。然而, 随机选取隐含层参数造成 ELM 学习性能不稳定, 将核函数引入 ELM, 能够有效提高 ELM 求解的稳定性和解决回归问题的能力。

ELM 算法的神经网络函数如公式(11)所示。

$$f(x) = \mathbf{h}(x)\boldsymbol{\beta} \quad (11)$$

式中： $\boldsymbol{\beta}$ 为输出层权重向量； $\mathbf{h}(x)$ 为神经元 $h(x)$ 组成的向量。

ELM算法通过最小化输出误差确保预测精度，最小化输出权重 $\boldsymbol{\beta}$ 保证网络的泛化能力。采用最小二乘法求解输出权重 $\boldsymbol{\beta}$ ，即

$$\boldsymbol{\beta} = \mathbf{H}^* \mathbf{O} = \mathbf{H}^T (\mathbf{H}\mathbf{H}^T)^{-1} \mathbf{O} = \mathbf{H}^T (1/C + \mathbf{H}\mathbf{H}^T)^{-1} \mathbf{O} \quad (12)$$

式中： $\mathbf{H}$ 为隐含层矩阵； $\mathbf{H}^*$ 为 $\mathbf{H}$ 的广义逆矩阵； $\mathbf{O}$ 为预测目标值向量。依据岭回归理论，增加正常数 $1/C$ ，可以使求解结果更稳定，泛化能力更强。

引入核函数，则ELM算法中的公式可用核矩阵形式表示

$$\boldsymbol{\Omega}_{\text{ELM}} = \mathbf{H}\mathbf{H}^T : \Omega_{\text{ELM}(i,j)} = h(x_i)h(x_j) = K(x_i, x_j) \quad (13)$$

因此，KELM输出函数表示为

$$f(x) = \mathbf{h}(x)\mathbf{H}^T (1/C + \mathbf{H}\mathbf{H}^T)^{-1} \mathbf{O} = \begin{bmatrix} K(x, x_1) \\ K(x, x_2) \\ \dots \\ K(x, x_n) \end{bmatrix}^T (1/C + \boldsymbol{\Omega}_{\text{ELM}})^{-1} \mathbf{O} \quad (14)$$

由公式(14)可见，引入核函数后，KELM算法不再需要设置隐含层参数，但KELM算法的回归预测性能受核函数参数和广义逆矩阵的参数 $C$ 影响，因此，需要合理选择核函数参数和广义逆矩阵的参数 $C$ ，KELM算法的基本原理可参考文献[13]。

### 3 DE算法优化KPCA和KELM参数

KPCA的核参数(记为 $r_1$ )的合理选择与否决定了KPCA特征提取效果，KELM的参数 $C$ 和核参数(记为 $r_2$ )选择影响KELM算法的回归性能，而KPCA和KELM参数的优化过程是相互依赖、相互制约的，应同时优化。显然，参数 $r_1$ 和 $C$ 、 $r_2$ 的优化是一个多参数组合优化问题。如果采用交叉验证法进行选取，计算量大且难以选取最优值。DE算法是一种基于种群迭代的随机搜索算法，通过变异、交叉、选择算子的作用下，个体向更高的适应度进化寻找问题最优解。在收敛速度和稳定性

方面，已被证明DE算法优于粒子群优化算法等几种知名随机算法。因此，本文采用差分进化算法组合优化参数 $r_1$ 、 $C$ 和 $r_2$ 。

DE算法的搜索目的是最终找到预测模型的参数组合( $r_1, C, r_2$ )，提高模型的预测精度，因此，个体适应度函数采用均方根误差进行评价。

$$Fitness = E_{RMSE} = \sqrt{\frac{1}{n_t} \sum_{i=1}^{n_t} (y_i - f(x_i))^2} \quad (15)$$

式中： $n_t$ 为测试样本数目； $y_i$ 为目标值； $f(x_i)$ 为模型的输出值。

模型的参数组合( $r_1, C, r_2$ ) $\in [2^{-3}, 2^{13}]$ 的DE算法优化步骤如下：

输入：训练样本集 $\{(\mathbf{x}_i, y_i)\}_{i=1}^n$ ，测试样本集 $\{(\mathbf{x}_i, y_i)\}_{i=1}^{n_t}$ 。

输出：模型的参数组合( $r_1, C, r_2$ )。

Step 1: 设置DE参数：维数 $D=3$ ，种群规模 $NP=25$ ，交叉因子 $F=0.5$ ，交叉概率 $CR=0.1$ ，预设精度为 $10^{-6}$ ，最大进化代数为200，( $r_1, C, r_2$ ) $\in [2^{-3}, 2^{13}]$ ，令进化代数 $t=0$ ；

Step 2: 随机产生初始种群个体；

Step 3: 计算每个个体的适应度值；

① 按1.3节算法计算当KPCA核参数为 $r_1$ 时，训练样本集的主元集 $\mathbf{t}$ 和测试样本集的主元集 $\mathbf{t}_t$ ；

② 构造KELM的训练样本集和测试样本集，分别为 $\{(\mathbf{t}_i, y_i)\}_{i=1}^n$ 和 $\{(\mathbf{t}_{ti}, y_i)\}_{i=1}^{n_t}$ ；

③ 由公式(14)计算当KELM参数为 $C, r_2$ 时，测试样本的预测值；

④ 由公式(15)计算得到个体的适应度值；

Step 4: 种群个体进行变异、交叉和选择操作，产生下一代种群，令 $t=t+1$ ；

Step 5: 是否满足结束条件(预设精度或最大进化代数)，若满足，转至Step6；否则，转至Step3；

Step 6: 输出最优个体的( $r_1, C, r_2$ )。

### 4 RTKPCA的击穿电压预测建模

日常监测变压器油的各项参量从不同角度反

映出油的固有特性, 击穿电压集中体现油的绝缘性能, 各参量以及与击穿电压之间存在有内在的必然的联系。闪点的高低反映出油绝缘性能的变化, 闪点越高, 绝缘强度越大; 总烃含量反映了油中溶解故障特征气体的产量, 总烃越高, 油的绝缘性能越差; 酸值反映出油的老化程度, 酸性产物会腐蚀绝缘材料, 从而影响击穿电压; 击穿电压最灵敏的因素是微水含量, 0.005% 的微水含量就能影响油的绝缘强度。因此, 以闪点、总烃、闪点、微水含量作为变压器油击穿电压预测模型的输入变量, 本文提出的 RTKPCA-KELM 预测模型结构图如图 1 所示。




图 1 RTKPCA-KELM 的模型结构图  
Fig. 1 Model structure of RTKPCA-KELM

RTKPCA-KELM 模型算法的基本步骤如下:

(1) 按第 3 节的 DE 算法优化 RTKPCA-KELM 模型参数(将训练样本集  $X \in R^{n \times m}$ ,  $Y \in R^{n \times 1}$  中 3/4 样本用于训练, 1/4 样本用于测试), 得到最优组合参数( $r_1$ ,  $C$ ,  $r_2$ );

(2) 输入训练样本集  $X \in R^{n \times m}$ ,  $Y \in R^{n \times 1}$  和测试样本集  $X_t \in R^{n_t \times m}$ ,  $Y_t \in R^{n_t \times 1}$ , 按 1.3 节算法计

算得到训练样本集的主元集  $t$  和测试样本集的主元集  $t_t$ ;

(3) 构造 KELM 的训练样本集和测试样本集, 分别为  $t \in R^{n \times k}$ ,  $Y \in R^{n \times 1}$  和  $t_t \in R^{n_t \times k}$ ,  $Y_t \in R^{n_t \times 1}$ ;

(4) 按公式(14)计算得到测试样本的预测值;

(5) 性能评价; 以均方根误差  $E_{RMSE}$ (见公式(15))和平均相对误差  $E_{ARE}$ (见公式(16))进行评价;

$$E_{ARE} = \frac{1}{n_t} \sum_{i=1}^{n_t} \frac{|y_i - f(x_i)|}{y_i} \quad (16)$$

## 5 实验结果分析

实验用数据见文献[2], 共 51 例变压器油击穿电压测试样本, 以 43 例为训练样本, 8 例为测试样本。为了表明本文提出的基于 RTKPCA 的变压器油击穿电压 KELM 预测建模方法的有效性, 将本文方法简记为 RTKPCA-KELM, 与文献[7] 提出的 RTPCA 的变压器油击穿电压 LSSVM 预测建模方法(简记为 RTPCA-LSSVM), 以及为验证 KELM 建模的有效性, 与 RTKPCA-LSSVM 和 RTPCA-KELM 进行比较。RTKPCA-KELM、RTKPCA-LSSVM、RTPCA-KELM 和 RTKPCA-LSSVM 这 4 种模型参数均采用差分进化算法选取, LSSVM 的核参数仍记为  $r_2$ , 惩罚参数仍记为  $C$ 。这 4 种模型的预测结果如表 1 所示, 预测性能见表 2。

表 1 各种模型的预测结果  
Tab. 1 Prediction results of various models

测量值/kV	RTPCA-LSSVM		RTPCA-KELM		RTKPCA-LSSVM		RTKPCA-KELM	
	参数(/, 14.20, 4.22)		参数(/, 98.56, 7.79)		参数(16.74, 22.13, 140.01)		参数(660.47, 85.64, 7.27)	
	预测值/kV	相对误差/%	预测值/kV	相对误差/%	预测值/kV	相对误差/%	预测值/kV	相对误差/%
58	57.64	0.63	58.81	0.26	58.79	0.55	57.08	0.04
60	58.77	2.05	60.10	1.31	60.89	0.76	59.53	1.05
60	58.97	1.71	59.58	0.75	60.30	0.02	59.02	0.76
58	58.05	0.08	58.87	0.92	59.31	1.63	58.45	1.27
56	53.98	3.61	51.44	0.26	53.33	5.10	57.44	0.62
61	58.91	3.43	59.35	3.79	60.26	1.42	58.95	4.32
60	57.09	4.85	56.47	4.72	58.60	2.38	58.89	1.86
58	57.39	1.05	57.64	0.15	58.34	0.33	57.90	0.11

表2 各种模型的预测误差比较  
Tab. 2 Comparison of prediction error

模型	相对误差大于2%个数	最大相对误差/%	$E_{ARE}$ /%	$E_{RMSE}$
RTPCA-LSSVM	4	4.85	2.18	1.580 9
RTPCA-KELM	2	4.72%	1.52	1.345 8
RTKPCA-LSSVM	2	5.10%	1.52	1.234 3
RTKPCA-KELM	1	4.32%	1.25	1.087 1

由表1和表2可见,RTKPCA-KELM、RTKPCA-LSSVM、RTPCA-KELM和RTPCA-LSSVM这4种模型,均方根误差和平均相对误差最优的都是本文提出的RTKPCA-KELM建模方法,分别为1.0871和1.25%。与RTPCA-KELM相比,RTKPCA-KELM采用RTKPCA提取的主元变量比RTPCA包含更丰富的非线性特征,提高了预测精度,均方根误差和平均相对误差分别降低了19.22%和17.76%;与RTKPCA-LSSVM相比,RTKPCA-KELM采用KELM建模,利用KELM强大的非线性拟合能力,取得了较好的预测结果,均方根误差和平均相对误差分别降低了11.93%和17.76%;而对比RTPCA-LSSVM,本文提出的预测建模方法更为有效,均方根误差和平均相对误差分别显著降低了31.26%和42.66%。这4种方法相对误差大于2%的测试样本

个数,依次为1、2、2和4,最大相对误差为4.32%、5.10%、4.72%和4.85%,表明在这4种方法中,RTKPCA-KELM预测结果更稳定,具有最强鲁棒性,而RTPCA-LSSVM最差。

为表明DE算法优化模型参数的有效性,表3给出了采用交叉验证法选取模型参数的各种模型的预测结果,即 $r_1, C, r_2 \in \{2^{-3}, 2^{-2}, \dots, 2^0, \dots, 2^{13}\}$ ,表4为交叉验证法各模型的预测性能对比。由表3和表4可见,采用交叉验证法,RTKPCA-KELM, RTKPCA-LSSVM, RTPCA-KELM和RTPCA-LSSVM这4种模型,均方根误差最优的是RTKPCA-KELM,为1.2084,比RTPCA-KELM降低了18.38%。平均相对误差最优的是RTKPCA-LSSVM,为1.47%,比RTPCA-LSSVM降低了31.31%,同样表明了基于RTKPCA特征提取的有效性。而在相同特征提取方法的条件下,用KELM建模的均方根误差要低于LSSVM。

对比表2和表4可以看出,用DE算法选取模型参数比交叉验证法选取模型参数,各种模型的性能均在不同程度上得到提高,RTKPCA-KELM, RTKPCA-LSSVM, RTPCA-KELM, RTPCA-LSSVM的均方根误差依次降低了10.04%, 7.28%, 9.10%, 5.60%。实验结果均表明了本文提出的基于RTKPCA的变压器油击穿电压KELM预测模型具有较强的鲁棒性,较高的预测精度和泛化能力。

表3 交叉验证法的各种模型预测结果  
Tab. 3 Prediction results of various models by cross validation method

测量值/kV	RTPCA-LSSVM		RTPCA-KELM		RTKPCA-LSSVM		RTKPCA-KELM	
	参数(1, 2 <sup>3</sup> , 2 <sup>2</sup> )		参数(1, 2 <sup>6</sup> , 2 <sup>7</sup> )		参数(2 <sup>4</sup> , 2 <sup>3</sup> , 2 <sup>6</sup> )		参数(2 <sup>10</sup> , 2 <sup>7</sup> , 2 <sup>3</sup> )	
	预测值 /kV	相对误差 /%	预测值 /kV	相对误差 /%	预测值 /kV	相对误差 /%	预测值 /kV	相对误差 /%
58	57.85	0.27	58.29	0.51	57.73	0.46	57.76	0.42
60	58.85	1.91	59.71	0.48	59.95	0.08	59.03	1.62
60	59.13	1.45	59.79	0.35	59.78	0.37	59.41	0.98
58	58.02	0.04	58.90	1.55	58.58	1.00	58.47	0.81
56	54.47	2.74	57.30	2.33	52.75	5.80	55.22	1.40
61	58.50	4.11	58.17	4.63	60.32	1.12	58.57	3.99
60	56.63	5.62	57.39	4.35	58.37	2.71	58.11	3.15
58	57.42	1.00	58.19	0.32	58.14	0.23	58.00	0.00



表 4 交叉验证法的各种模型预测误差比较  
Tab. 4 Comparison of various models' prediction error by cross validation method

模型	相对误差大于 2% 个数	最大相对误差/%	$E_{ARE}$ /%	$E_{RMSE}$
RTPCA-LSSVM	3	5.62	2.14	1.674 7
RTPCA-KELM	3	4.63	1.81	1.480 6
RTKPCA-LSSVM	2	5.80	1.47	1.331 2
RTKPCA-KELM	2	3.99	1.55	1.208 4

## 6 结论

本文针对变压器油击穿电压在线测量困难, PCA 难以提取相对空间的非线性特征, 提出了基于 RTKPCA 的变压器油击穿电压 KELM 预测建模方法。利用相对变换非线性放大和抑制噪声作用, KPCA 降维和非线性特征提取的优势, 提出的 RTKPCA 特征提取方法有效地提高了模型预测精度, 采用核极限学习机建立变压器油击穿电压的预测模型并利用差分算法选取模型参数, 有效地提高了模型的预测性能。实验结果表明, 本文提出的基于 RTKPCA-KELM 的变压器油击穿电压预测模型的均方根误差和平均相对误差分别为 1.087 1、0.012 5, 低于 RTPCA-LSSVM 预测模型均达到 30% 以上, 表明本文提出的预测建模方法是有效性的。

## 参考文献:

- [1] 申巍, 范廷东, 曹雯, 等. 油纸绝缘简单模型的剩余击穿电压预测[J]. 高电压技术, 2011, 37(4): 910-915.  
Shen Wei, Fan Tingdong, Cao Wen, et al. Residual breakdown voltage prediction of simple oil paper insulation model[J]. High Voltage Engineering, 2011, 37(4): 910-915.
- [2] 李睿, 曹顺安, 盛凯. BP 神经网络用于预测多参数关联变压器油的性能[J]. 计算机与应用化学, 2008, 25(6): 737-740.  
Li Rui, Cao Shun'an, Sheng Kai. BP artificial neural network for the prediction of transformer oil performance with multi-parameter correlation [J].

- Computers and Applied Chemistry, 2008, 25(6): 737-740.
- [3] 王磊, 李桂香, 王元麒, 等. 基于 LSSVM 的天然气脱 CO<sub>2</sub> 膜分离在线软测量模型[J]. 系统仿真学报, 2014, 26(8): 1836-1840.  
Wang Lei, Li Guixiang, Wang Yuanqi, et al. On-line soft measurement model for CO<sub>2</sub> separating from natural gas membrane separation process based on LSSVM[J]. Journal of System Simulation, 2014, 26(8): 1836-1840.
- [4] 石怀涛, 刘建昌, 张羽, 等. 基于相对变换 PLS 的故障检测方法[J]. 仪器仪表学报, 2012, 33(4): 816-822.  
Shi Huaitao, Liu Jianchang, Zhang Yu, et al. Fault detection method based on relative transformation partial least squares[J]. Chinese Journal of Scientific Instrument, 2012, 33(4): 816-822.
- [5] 文贵华. 面向机器学习的相对变换[J]. 计算机研究与发展, 2008, 45(4): 612-618.  
Wen Guihua. Relative transformation for machine learning[J]. Journal of Computer Research and Development, 2008, 45(4): 612-618.
- [6] Shi H T, Liu J C, Xue P, et al. Improved relative-transformation principal component analysis based on Mahalanobis distance and its application for fault detection[J]. Acta Automatica Sinica (S1874-1029), 2013, 39(9): 1533-1542.
- [7] 唐勇波, 彭涛, 熊印国, 等. 相对变换主元分析的变压器油击穿电压预测[J]. 仪器仪表学报, 2015, 36(7): 1640-1645.  
Tang Yongbo, Peng Tao, Xiong Yinguo, et al. Breakdown voltage prediction method for transformer oil based on relative transformation principal component analysis[J]. Chinese Journal of Scientific Instrument, 2015, 36(7): 1640-1645.
- [8] Lee J M, Yoo C, Choi S W, et al. Non-linear process monitoring using kernel principal component analysis[J]. Chemical Engineering Science (S0009-2509), 2004, 59(1): 223-234.
- [9] 高智勇, 梁银林, 高建民, 等. 基于集成熵 KPCA 的复杂机电系统状态监测方法[J]. 计算机集成制造系统, 2015, 21(5): 1327-1333.  
Gao Zhiyong, Liang Yinlin, Gao Jianmin, et al. State monitoring of complex electromechanical system based on integrated entropy of KPCA[J]. Computer Integrated Manufacturing Systems, 2015, 21(5): 1327-1333.
- [10] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: theory and applications[J]. Neurocomputing (S0378-7796), 2006, 70(1): 489-501.

- [11] 徐嘉明, 张卫强, 杨登舟, 等. 基于流形正则化极限学习机的语种识别系统[J]. 自动化学报, 2015, 41(9): 1680-1685.  
Xu Jiaming, Zhang Weiqiang, Yang Dengzhou, et al. Manifold regularized extreme learning machine for language recognition[J]. Acta Automatica Sinica, 2015, 41(9): 1680-1685.
- [12] 李新利, 李楠, 孙愉佳, 等. 火焰自由基成像和极限学习机在 NO<sub>x</sub> 排放预测中的研究[J]. 系统仿真学报, 2016, 28(5): 1179-1185.  
Li Xinli, Li Nan, Sun Yujia, et al. Research on flame radical imaging and extreme learning machine to prediction of NO<sub>x</sub> emissions[J]. Journal of System Simulation, 2016, 28(5): 1179-1185.
- [13] Huang G B, Zhou H, Ding X, et al. Extreme learning machine for regression and multiclass classification[J]. Systems, Man, and Cybernetics, Part B: IEEE Transactions on Cybernetics (S1083-4419), 2012, 42(2): 513-529.
- [14] 刘念, 张清鑫, 刘海涛. 基于核函数极限学习机的微电网短期负荷预测方法[J]. 电工技术学报, 2015, 30(8): 218-224.  
Liu Nian, Zhang Qingxin, Liu Haitao. Online short-term load forecasting based on ELM with kernel algorithm in micro-grid environment[J]. Transactions of China Electrotechnical Society, 2015, 30(8): 218-224.
- [15] 张文专, 龙文, 焦建军. 基于差分进化算法的混沌时间序列预测模型参数组合优化[J]. 物理学报, 2012, 61(22): 5061-5067.  
Zhang Wenzhuan, Long Wen, Jiao Jianjun. Parameter determination based on composite evolutionary algorithm for reconstructing phase-space in chaos time series[J]. Acta Physica Sinica, 2012, 61(22): 5061-5067.
- [16] 刘增良, 周松林, 周同旭. 基于 IDE-WNN 的短期风电功率预测及概率评估[J]. 系统仿真学报, 2016, 28(2): 476-482.  
Liu Zengliang, Zhou Songlin, Zhou Tongxu. Short-term prediction of wind power based on IDE-WNN and probabilistic evaluation[J]. Journal of System Simulation, 2016, 28(2): 476-482.
- [17] 邱晓红, 江阳, 李渤. 分形变异因子修正的差分进化算法[J]. 模式识别与人工智能, 2015, 28(2): 132-138.  
Qiu Xiaohong, Jiang Yang, Li Bo. Fractal mutation factor correcting differential evolution algorithm[J]. Pattern Recognition and Artificial Intelligence, 2015, 28(2): 132-138.

## 《系统仿真学报》荣获“2017 中国国际影响力优秀学术期刊”证书

由中国学术期刊（光盘版）电子杂志社与清华大学图书馆联合成立的中国学术文献国际评价研究中心，发布了 2017 版《中国学术期刊国际引证年报》，《系统仿真学报》荣获“2017 中国国际影响力优秀学术期刊”。

《年报》（2017 版）采用的统计源期刊为 20192 种，涵盖 WoS 收录的 SCI 期刊 8874 种、SSCI 和 A&HCI 期刊 4645 种，ESCI 期刊 5578 种；增补期刊 1762 种。参照中外文学术期刊总被引频次、影响因子、半衰期等各项国际引证指标，计算期刊影响力指数(CI)，对国内 6210 种学术期刊排序，遴选了人文社科、自然科学与工程技术两个类别的 TOP10% 为国际影响力品牌学术期刊。TOP5% 以内的期刊为“最具国际影响力学术期刊”、TOP5-10% 之间的为“国际影响力优秀学术期刊”。