

基于KPCA-IPOA-LSSVM的变压器电热故障诊断

陈尧¹, 周连杰²

(1. 辽宁工程技术大学电气与控制工程学院, 辽宁 葫芦岛 125105; 2. 开滦(集团)有限责任公司, 河北 唐山 063000)

摘要: 为解决油浸式变压器故障诊断准确率低的问题, 提出了一种核主成分分析(kernel principal component analysis, KPCA)与改进鹈鹕优化算法(improved pelican optimization algorithm, IPOA)优化最小二乘支持向量机(least squares support vector machine, LSSVM)的变压器故障诊断方法。首先用KPCA对多维变压器故障数据进行特征提取, 降低计算复杂度。其次引入Logistic混沌映射、自适应权重策略和透镜成像反向学习策略对鹈鹕优化算法(pelican optimization algorithm, POA)进行改进。最后建立了KPCA-IPOA-LSSVM故障诊断模型, 诊断精度为94.24%, 与PCA-IPOA-SVM、KPCA-IPOA-SVM、KPCA-WOA-LSSVM和KPCA-POA-LSSVM故障诊断模型进行对比, 准确率分别提升了18.31%、11.53%、11.87%、7.46%。结果表明, 所提出的变压器故障诊断模型有效提高了故障诊断的准确率, 证明了该诊断模型具有一定的理论研究和实际工程应用意义。

关键词: 变压器; 鹈鹕优化算法; 最小二乘支持向量机; 核主成分分析; 故障诊断

Electrical and Thermal Fault Diagnosis of Transformer Based on KPCA-IPOA-LSSVM

CHEN Yao¹, ZHOU Lianjie²

(1. School of Electrical and Control Engineering, Liaoning Technical University, Huludao, Liaoning 125105 China;

2. Kailuan (Group) Co., Ltd., Tangshan, Hebei 063000 China)

Abstract: In order to solve the problem of low accuracy of fault diagnosis of oil-immersed transformers, a transformer fault diagnosis method of kernel principal component analysis (KPCA) with improved pelican optimization algorithm (IPOA) optimized least squares support vector machine (LSSVM) is proposed. Firstly, KPCA is used to extract features from multidimensional transformer fault data, reducing computational complexity. Secondly, logistic chaotic mapping, adaptive weight strategy, and lens imaging reverse learning strategy are introduced to improve the pelican optimization algorithm (POA). Finally, the KPCA-IPOA-LSSVM fault diagnostic model is established, and the diagnostic accuracy is 94.24%. Compared with the PCA-IPOA-SVM, KPCA-IPOA-SVM, KPCA-WOA-LSSVM, and KPCA-POA-LSSVM fault diagnostic models, the accuracy is improved respectively by 18.31%, 11.53%, 11.87%, 7.46%. The results show that the transformer fault diagnosis model proposed in this paper effectively improves the accuracy of fault diagnosis, proving that the diagnostic model has certain significance in theoretical research and practical engineering application.

Key words: transformer; pelican optimization algorithm; least squares support vector machine; kernel principal component analysis; fault diagnosis

0 引言

油浸式电力变压器作为电力系统中用来改变电压和传递电能的主要设备, 其运行的状况直接影响

电力系统供电的可靠性^[1]。由于变压器是昂贵且复杂的电力设备, 维修成本极高, 所以变压器一旦发生故障, 变压器内部产生的易燃气体在故障电弧的影响下很容易引发变压器燃烧, 造成安全隐患, 因此及时发现并处理变压器故障具有很重大的工程意义^[2-3]。

变压器产生电、热故障时导致变压器和绝缘板

基金项目: 国家自然科学基金资助项目(51974151)。

Foundation item: Supported by the National Natural Science Foundation of China (51974151).

分解,产生 H_2 、 CH_4 、 C_2H_6 、 C_2H_4 和 C_2H_2 等气体,气体会溶于变压器油中,在内部产生初期故障,对产生的气体进行分析能够检测故障,所以油中溶解气体分析(dissolved gases analysis, DGA)是应用较广的诊断方法^[4-5]。目前,变压器故障诊断采用 DGA 与人工智能方法相结合的研究一般可分为神经网络^[6]、极限学习机、专家系统与支持向量机(SVM)等方法^[7-9]。文献[10]将联邦学习结合 Self-attention 机制优化 BP 神经网络的变压器故障诊断模型,显著提高了电力变压器故障诊断的准确性。文献[11]采用人工鱼群算法与极限学习机(extreme learning machine, ELM)模型相结合,提高了变压器故障诊断的精度。文献[11-12]以专家系统为基础对变压器故障类型进行诊断分析,诊断模型具有一定的有效性与可行性。文献[13-14]将多种智能优化算法优化 SVM 进行变压器故障诊断,提升了故障分类的准确率与故障诊断可行性。文献[10-14]描述的诊断模型虽然有效地提升了故障诊断的诊断精度,但其中神经网络收敛速度慢,依赖样本的适应性;极限学习机的准确度没有传统神经网络高;当知识库不足时专家系统的判断准确性得不到保证。文献[15]提出一种改进灰狼算法优化最小二乘支持向量机(least squares support vector machine, LSSVM)的变压器故障诊断模型,相较于单一使用 LSSVM 的诊断模型准确率提高了 14%。文献[16]提出了基于 LSSVM 结合改进果蝇优化算法的诊断模型,该模型能够有效并准确地识别故障类型,该方法有较高的精度和应用价值。现阶段,国内外学者采用人工智能优化算法针对变压器开展了故障诊断研究,为该行业实践提供了大量案例研究参考。

综上所述,本文提出一种基于核主成分分析(kernel principal component analysis, KPCA)与改进鹈鹕优化算法(improved pelican optimization algorithm, IPOA)相结合的 LSSVM 变压器故障诊断模型。先利用 KPCA 对 421 组变压器故障数据进行处理,去除冗余的特征信息;然后引入 logistic 混沌映射、自适应权重策略以及透镜成像反向学习策略对鹈鹕优化算法(pelican optimization algorithm, POA)进行改进;改进的鹈鹕优化算法能够更好地优化 LSSVM 的惩罚系数 C 和核函数参数 g ,最后将 KPCA 降维后的特征量作为 IPOA-LSSVM 模型的输入,经过实验分析所建立的 KPCA-IPOA-LSSVM

模型能够更快地收敛,相较于其他模型具有更高诊断精度。

1 数据预处理

1.1 故障特征气体选择

当变压器正常运行时油箱为密封结构,其中的气体含量与组成相对稳定,当变压器内部发生故障,如热故障与击穿放电故障,会产生故障独有的气体,产生的气体主要由 H_2 、 CH_4 、 C_2H_6 、 C_2H_4 、 C_2H_2 等气体组成,所以采用油中溶解气体分析(dissolved gas analysis, DGA)对变压器故障进行诊断是最常用的方法,故障的类型如果单一地依靠一种气体进行判断,由于故障信息不够完整,会影响判断的准确率,因此,基于 CH_4/H_2 、 C_2H_4/C_2H_6 、 C_2H_2/C_2H_4 的改进三比值法,我们将数据在原来的基础上扩充到 21 维,其中 TH 是 CH_4 、 C_2H_6 、 C_2H_4 以及 C_2H_2 这 4 种气体的总和,具体的气体比值如表 1 所示。

表 1 油中溶解气体数据比值
Tab. 1 Ratio of dissolved gas data in oil

编号	特征量	编号	特征量
1	H_2	12	CH_4/C_2H_4
2	CH_4	13	CH_4/C_2H_2
3	C_2H_6	14	C_2H_4/C_2H_6
4	C_2H_4	15	C_2H_2/C_2H_6
5	C_2H_2	16	C_2H_2/C_2H_4
6	TH	17	H_2/TH
7	H_2/CH_4	18	CH_4/TH
8	H_2/C_2H_6	19	C_2H_2/TH
9	H_2/C_2H_4	20	C_2H_4/TH
10	H_2/C_2H_2	21	C_2H_6/TH
11	CH_4/C_2H_6		

1.2 KPCA 数据处理

为更好地处理数据集,去除冗余特征,对数据利用 KPCA 进行降维,选择主要特征作为模型的输入,降低计算复杂度,提高模型的泛化能力,减小过拟合的风险并提升诊断精度。目前常用的数据处理方法有主成分分析(principal component analysis, PCA)以及 KPCA,传统的 PCA 在处理非线性问题很难作出优化选择, KPCA 对于非线性问题处理的实际效果表现得更可靠,所以采用 KPCA 对 DGA 数据进行降维处理^[17-18]。KPCA 是在 PCA 的基础上使用核函数将原始数据投影到方便使用线性分析的高维

空间,以达到初始故障数据非线性变化的目标。

KPCA 的原理是令初始数据 $\mathbf{x} = [x_{ij}]_{n \times m}$, 找到一个映射 ϕ 将 $\mathbf{x}$ 在高维空间 F 中投影来进行线性分析, F 的协方差矩阵 $\mathbf{C}_F$ 为:

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

式中: $\phi(x_i)$ 为径向基核函数; n 为数据样本总数。

求解特征方程得出其主要成分为:

$$\lambda \mathbf{V} = \mathbf{C}_F \mathbf{V} \quad (2)$$

式中: λ 为矩阵 $\mathbf{C}_F$ 的特征值; $\mathbf{V}$ 为特征向量。

为了避免高维运算,引入 $n \times n$ 维核矩阵 $\mathbf{K}_{ij}$ 。

$$\mathbf{K}_{ij} = \phi(x_i) \phi(x_j) \quad (3)$$

引入径向基(radial basis function, RBF)核函数计算。

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|}{2\sigma^2}\right) \quad (4)$$

式中 σ 为函数的宽度参数。

对核矩阵 $\mathbf{K}_{ij}$ 进行中心化处理,可以得到简化后的公式如式(5)所示。

$$\mathbf{K}^* = \mathbf{K} - \mathbf{IK} - \mathbf{KI} + \mathbf{IKI} \quad (5)$$

式中: $\mathbf{K}^*$ 为 $\mathbf{K}_{ij}$ 简化后的核矩阵; $\mathbf{I}$ 为 n 阶单位矩阵。进一步化简可得:

$$\lambda \alpha = \frac{1}{n} \mathbf{K}^* \alpha \quad (6)$$

式中: α 为列向量; n 为维数。

为确定主要的影响因子 c , 根据式(7)计算出 c 并挑选贡献率高的 m 个主元素, 令贡献率高于 85%, 计算公式如式(7)所示。

$$c = \frac{\sum_{i=1}^m \lambda_i}{\sum_{i=1}^n \lambda_i} \geq 85\% \quad (7)$$

式中 λ_i 为第 i 个向量的特征值。

最后根据式(8)计算出线性样本, 计算公式为:

$$\begin{aligned} \mathbf{F}_i &= \left[\sum_{i=1}^n \alpha_i \phi(x_i) \right]^T \\ &= \alpha^T [\phi(x_1, x), \dots, \phi(x_i, x)]^T \end{aligned} \quad (8)$$

式中: $\mathbf{F}_i$ 为线性样本函数值; α_i 为第 i 个样本的列向量; x 为数据样本。

本文中所选取的 421 组故障数据经过 KPCA 降维, 降维后的主要成分数据占比如图 1 所示。图 1 中,

前 8 个主要成分的数据占比之和为 0.852 11, 即累积贡献率之和为 85.211 %, 满足式(7), 所以选取图 1 中的 8 个主要成分作为故障诊断的数据输入。




图 1 主要成分累计贡献率

Fig. 1 Cumulative contributions of major components

2 改进 POA 算法

2.1 POA 算法简介

鸚鵡优化算法(POA)是根据鸚鵡在自然中捕猎行为产生灵感, 在 2022 年由帕维尔和穆罕默德提出^[19]。该狩猎过程分为两个阶段: 逼近猎物(勘探阶段), 水面飞行(开发阶段)。各阶段的数学公式如下。

1) 第一阶段逼近猎物(勘探阶段)

鸚鵡向确定的猎物位置区域进行移动, 对这个行为进行建模。

$$x_{i,j}^{p_1} = \begin{cases} x_{i,j} + N_{\text{rand}}(p_j - Ix_{i,j}), & F_p < F_i^{\text{target}} \\ x_{i,j} + N_{\text{rand}}(x_{i,j} - p_j), & \text{其他} \end{cases} \quad (9)$$

式中: $x_{i,j}^{p_1}$ 为基于阶段 1 的第 j 维中第 i 只鸚鵡的更新后的位置, p_1 为第一阶段的位置; N_{rand} 为随机数, 且 $N_{\text{rand}} \in [0, 1]$; I 为 1 或 2 的随机整数; p_j 为第 j 维猎物的位置; F_p 为目标函数值, P 为目标函数值所在位置; F_i^{target} 为第 i 只鸚鵡所在位置目标函数值。

在 POA 算法中, 如果目标函数值在该位置得到改善, 则接受鸚鵡的新位置。在这种类型的更新中, 也被称为有效更新, 该算法不能移动到非最优区域。这个过程可以用式(10)描述。

$$x_i = \begin{cases} x_i^{p_1}, & F_i^{p_1} < F_i \\ x_i, & \text{其他} \end{cases} \quad (10)$$

式中: x_i 第 i 个鸚鵡的当前位置; $x_i^{p_1}$ 为第 i 个鸚鵡的新位置; $F_i^{p_1}$ 为基于第一阶段更新后的第 i 个鸚鵡新位置的目标函数值。

2) 第二阶段水面飞行(开发阶段)

鸚鵡在水面飞行, 这种行为使得它们在攻击区域能够捕获更多的猎物, 对这个策略进行建模, 如式(11)所示。

$$x_{i,j}^{p_2} = x_{i,j} + R \left(1 - \frac{t}{T} \right) (2N_{\text{rand}} - 1) x_{i,j} \quad (11)$$

式中: $x_{i,j}^{p_2}$ 为基于第二阶段更新后第 i 个鸚鵡在第 j 维的位置; $R=0.2$; $R(1-t/T)$ 为 $x_{i,j}$ 的邻域半径; t 为迭代次数; T 为最大迭代次数。

在这个阶段, 有效的更新也被用来接受或拒绝新的鸚鵡位置, 数学建模如下。

$$x_i = \begin{cases} x_i^{p_2}, & F_i^{p_2} < F_i \\ x_i, & \text{其他} \end{cases} \quad (12)$$

式中: $x_i^{p_2}$ 为第 i 个鸚鵡的新位置; $F_i^{p_2}$ 为基于第二阶段更新后的第 i 个鸚鵡新位置的目标函数值。

2.2 改进 POA

针对 POA 算法在初始化阶段容易错过最优解, 以及算法在勘探和开发两个阶段易发生局部最优的情况, 采用融合 3 个策略对算法进行改进: 首先为提升种群的多样性在初始化阶段引入 logistic 混沌映射; 其次在勘探阶段采用自适应惯性权重策略提高算法寻优能力; 最后在开发阶段添加透镜成像反向学习策略, 避免算法陷入局部最优。

2.2.1 logistic 混沌映射

对初始化阶段进行优化的最常用的方法是在该阶段引入映射, 常用的混沌映射有帐篷混沌映射、立方体混沌映射等。本文应用 logistic 混沌映射, 其计算复杂度低, 实现也相对简单^[20], 逻辑映射表达式为:

$$y_i = by_{i-1}(1 - y_{i-1}) \quad (13)$$

式中: $y_{i-1} \in [0, 1]$; b 为控制参数, $b \in [1, 4]$, 只有当 $b \in [3.569\ 945\ 6, 4]$ 时 Logistic 映射才具有混沌性质。一般我们选取 $b=4$, 此时该映射处于完全混沌状态。图 2 为混沌状态对比图。

图 2 为 b 的值分别为 4 和 3.9 时的分布状态, 可见 $b=4$ 时混沌序列分布是最均匀的, 此时种群随机性最好。

加入 logistic 混沌映射更新后的种群初始化公式




图 2 混沌状态对比图

Fig. 2 Comparison of chaotic states

如式(14)所示。

$$x_{i,j} = l_j + y_i(u_j - l_j) \quad (14)$$

式中: $x_{i,j}$ 为加入映射后的第 i 个鸚鵡的第 j 维的位置; u_j 、 l_j 分别为初始化阶段种群的上界与下界。

2.2.2 自适应权重策略

POA 算法在迭代初期容易过早陷入局部最优, 使搜索失败。为克服这一弊端, 在算法第一阶段加入自适应权重系数, 权重系数在算法初期比较大, 此时促进全局搜索, 迭代后期权重系数变小, 促进局部搜索并加快收敛速度。这里自适应权重公式如式(15)所示。

$$\omega = 0.2 \cos \left(\pi \left(\frac{1-t}{T} \right) / 2 \right) \quad (15)$$

式中 ω 为自适应权重系数。

在第一阶段位置 $x_{i,j}^{p_1}$ 更新公式为:

$$x_{i,j}^{p_1} = \begin{cases} x_{i,j} + \omega N_{\text{rand}}(p_j - l x_{i,j}), & F_p < F_i \\ x_{i,j} + \omega N_{\text{rand}}(x_{i,j} - p_j), & \text{其他} \end{cases} \quad (16)$$

加入自适应权重后的位置更新公式能更好地平衡算法在该阶段的局部开发与全局探索能力, 从而优化算法的计算精度。

2.2.3 透镜成像反向学习策略

为解决算法在迭代后期陷入局部最优的问题, 一般采用两种方法, 一种方法以当前位置为初始值继续向其他区域寻找最优解, 第二种为舍弃当前, 向新的区域进行寻优, 本文采用第一种方法, 其原理图如图 3 所示。

在算法的开发阶段引入透镜成像来帮助算法逃出局部最优。其中透镜成像的原理: 最优点 x 的范围在上界 u_b 与下界 l_b 内, 高度为 h , 通过原点的凸透镜折射到数轴的另一端, 形成最优点 x 的反向解 x^* 。

图 3 中 x 为实物所在的坐标, h 为实物高度, u 为与凸透镜的距离; x^* 为经凸透镜折射后形成实像




图3 透镜成像原理图

Fig. 3 Schematic diagram of lens imaging

的坐标, h^* 为高度, v 为像距; f 为焦距; u_b 和 l_b 分别为搜索的上下范围, 透镜成像的原理可用式(17)表示。

$$\frac{\frac{(l_b + u_b)}{2} - x}{x^* - \frac{(l_b + u_b)}{2}} = \frac{h}{h^*} \quad (17)$$

令 $h/h^* = \eta$ 可得出区间内反向解 x^* 的公式, x^* 可用式(18)表示。

$$x^* = \frac{(l_b + u_b)}{2} + \frac{(l_b + u_b)}{2\eta} - \frac{x}{\eta} \quad (18)$$

式中 η 为缩放因子, 其反映了物像之间的比例, $\eta = 1$ 时, 就是一般的反向学习, 缩放因子的大小能够促使算法找到最好的位置, 本文选取 $\eta = 1.2 \times 10^4$ 。透镜成像反向学习策略就是对最优值 x 与反向解 x^* 的适应度值进行对比, 如果 x^* 的适应度值大于 x 的适应度值, 则 x^* 代替 x 加入种群参与迭代, 最优个体相较于普通个体具有更大的搜索区域, 所以加入反向学习策略对 POA 优化, 改善了 POA 逃出局部最优值的能力。

3 算法测试

为了验证 IPOA 算法的改进策略有效性, 本文选择了 4 组典型测试函数进行仿真实验。4 个基准测试函数的表达式及相关参数如式(19)所示。

$$\begin{cases} f_1(x) = \sum_{i=1}^D x_i^2 \\ f_2(x) = \sum_{i=1}^D \left(\sum_{j=1}^i x_j \right)^2 \\ f_3(x) = \sum_{i=1}^D [x_i^2 - 10 \cos(2\pi x_i) + 10] \\ f_4(x) = \frac{1}{4000} \left[\sum_{i=1}^D (x_i - 100)^2 \right] - \left[\prod_{i=1}^D \cos \left(\frac{x_i - 100}{\sqrt{i}} \right) \right] + 1 \end{cases} \quad (19)$$

式中: $f_1(x)$ 和 $f_2(x)$ 为单峰测试函数, 用以验证改进算法具有较快的收敛速度; $f_3(x)$ 和 $f_4(x)$ 为多峰函数, 用以验证算法的探索最优值能力; D 为测试函数维度; i 和 j 分别为 x 的位置信息。

为了验证 IPOA 算法性能优越性, 本文将 IPOA 与 POA 优化算法、WOA 优化算法^[21]、GWO 优化算法^[22]进行对比验证。测试函数参数设置为: 迭代次数为 1 000, 运行次数与种群数量均为 30, 取每次最优解, 具体算法数据对比如表 3 所示。

表3 不同算法仿真结果

Tab. 3 Simulation results of different algorithms

函数	算法	最优值	均值	标准差
$f_1(x)$	IPOA	0	3.709 0	$6.064 4 \times 10^{-6}$
	POA	$1.359 7 \times 10^{-236}$	2.13×10^1	$1.975 1 \times 10^2$
	WOA	$9.811 0 \times 10^{-162}$	7.43×10^1	$7.259 0 \times 10^2$
	GWO	$7.813 2 \times 10^{-118}$	3.72×10^1	$3.008 4 \times 10^2$
$f_2(x)$	IPOA	0	$9.534 1 \times 10^{-1}$	$2.992 2 \times 10^1$
	POA	$1.911 2 \times 10^{-225}$	$2.230 0 \times 10^1$	$4.340 6 \times 10^2$
	WOA	$1.683 8 \times 10^1$	$1.308 1 \times 10^3$	$2.073 5 \times 10^3$
	GWO	$5.981 5 \times 10^{-9}$	$9.580 0 \times 10^4$	$1.072 6 \times 10^3$
$f_3(x)$	IPOA	0	$6.353 5 \times 10^{-2}$	$1.982 4 \times 10^1$
	POA	$1.972 1 \times 10^{-118}$	$1.790 0 \times 10^{-1}$	$2.776 1 \times 10^1$
	WOA	0.843 9	$4.236 9 \times 10^1$	$6.899 9 \times 10^1$
	GWO	$4.777 8 \times 10^{-38}$	$4.890 0 \times 10^{-1}$	$4.482 1 \times 10^1$
$f_4(x)$	IPOA	0	$3.624 8 \times 10^{-2}$	$1.146 2 \times 10^1$
	POA	0	$3.090 9 \times 10^{-1}$	$5.426 4 \times 10^1$
	WOA	$8.446 4 \times 10^{-1}$	$1.710 1 \times 10^1$	$7.691 2 \times 10^1$
	GWO	$1.017 4 \times 10^{-2}$	$3.539 1 \times 10^{-1}$	$4.743 0 \times 10^1$

通过分析表 3 可以发现, 4 组测试函数中 IPOA 的测试结果明显优于其他 3 种优化算法。无论是单峰测试函数还是多峰测试函数, 均能找到 IPOA 理论最优值, 表明自适应权重策略和反向学习策略的引入增强了算法的勘探能力, 提高了收敛精度。

对于单峰函数 $f_1(x)$ 和 $f_2(x)$, IPOA 的标准差明显小于其他算法几个量级, 表明 IPOA 算法具有较强的算法稳定性; 对于多峰函数 $f_3(x)$ 和 $f_4(x)$ 。IPOA 同样能收敛到理论最优值, 并且 IPOA 的平均值和标准差略小于 WOA 算法和 GWO 算法。综上, IPOA 具有比其他 3 种优化算法更强的全局搜索能力以及更强的算法稳定性。

为了能直观分析出 IPOA 算法对比其他优化算法的寻优能力, 对每个测试函数分别绘制迭代曲

线。如图4—7所示。

从图4—7中可以看出 IPOA 算法收敛速度明显小于其他优化算法, 表明 logistic 混沌映射策略的引入, 提高了算法初始解质量, 帮助算法更快寻找到最优个体, 提高了算法前期收敛速度。随着迭代的进行, 由图4、图5、图7可以发现, WOA 算法和 GWO 算法收敛曲线相对平缓, 难以找到全局最优。POA 算法收敛速度虽然略优于 WOA 和 GWO 但对于 $f_1(x)$ 和 $f_2(x)$ 仍难以找到全局最优。而 IPOA 算法在4组测试函数中, 不但找到全局最优, 并且通过图6—7发现, IPOA 以低于10的速度快速收敛。由此再一次验证了自适应权重策略和反向学习策略的引入能够帮助算法跳出局部最优, 提高了收敛精度。




图4 $f_1(x)$ 迭代曲线

Fig. 4 $f_1(x)$ iteration curve

4 KPCA-IPOA-LSSVM 的故障诊断

4.1 最小二乘支持向量机

最小二乘支持向量机 (LSSVM) 是基于统计学习理论进行改进的支持向量机 (supporting vector machine, SVM)^[23], 相较于传统的 SVM, 在处理大规模数据时, 加入核函数的 LSSVM 具有计算速度快, 计算复杂度低的优点, 本文选用 LSSVM 对故障类型进行分类。

LSSVM 原理: 在数据总数为 n , 训练数据 (x_i, y_i) ($i = 1, 2, \dots, n$) 中, x_i 和 y_i 分别为输入和输出数据, x 为输入向量。利用映射函数 $\phi(x)$ 将输入空间映射到特征空间, 此时分类函数为:




图5 $f_2(x)$ 迭代曲线

Fig. 5 $f_2(x)$ iteration curves




图6 $f_3(x)$ 迭代曲线

Fig. 6 $f_3(x)$ iteration curves




图7 $f_4(x)$ 迭代曲线

Fig. 7 $f_4(x)$ iteration curves

$$f(x) = \mathbf{r}\phi(x) + b \quad (20)$$

式中: $\mathbf{r}$ 为权向量; b 为偏差量。对于 LSSVM 来说优化问题进而可以变成:

$$\min J(\mathbf{r}, \xi) = \frac{1}{2} \mathbf{r}^T \mathbf{r} + \frac{1}{2} C \sum_{i=1}^n \xi_i^2 \quad (21)$$

$$\text{s.t. } y_i [\mathbf{r}^T \phi(x_i) + b] - 1 + \xi_i = 0 \quad (22)$$

式中 ξ_i 和 C 分别为误差项和惩罚因子。为求解优化问题引入拉格朗日函数。

$$L(\mathbf{r}, b, \xi, \alpha) = J(\mathbf{r}, \xi) - \sum_{i=1}^n \alpha_i [\mathbf{r}^T \phi(x_i) + b + \xi_i - y_i] \quad (23)$$

式中 α_i 为拉格朗日乘子, 根据 KKT 条件, 对于 ω 、 b 、 ξ 、 α 求偏导。

$$\begin{cases} \frac{\partial L}{\partial \omega} = 0 \Rightarrow \omega = \sum_{i=1}^n \alpha_i y_i \phi(x_i) \\ \frac{\partial L}{\partial b} = 0 \Rightarrow \sum_{i=1}^n \alpha_i y_i = 0 \\ \frac{\partial L}{\partial \xi_i} = 0 \Rightarrow \alpha_i = C \xi_i \\ \frac{\partial L}{\partial \alpha_i} = 0 \Rightarrow y_i [\mathbf{r}^T \phi(x_i) + b] - 1 + \xi_i \end{cases} \quad (24)$$

消去 ω 和 ξ_i , 可得以下矩阵方程。

$$\begin{bmatrix} 0 & \mathbf{Y}^T \\ \mathbf{Y} & \Omega_{i,j} + C^{-1} \mathbf{I} \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{I}_n \end{bmatrix} \quad (25)$$

式中: $\mathbf{Y}^T = [Y_1, \dots, Y_n]$; $\alpha = [\alpha_1, \dots, \alpha_n]$; $\mathbf{I}_n = [1, \dots, 1]^T$; $\Omega_{i,j} = Y_i Y_j \phi(x_i)^T \phi(x_j) = Y_i Y_j K(x_i, x_j)$, $(i, j), i = 1, \dots, n$ 。

根据 Mercer 条件, 核函数与映射函数有以下关系。

$$K(x_i, x_j) = \phi(x_i)^T \phi(x_j) \quad (26)$$

此处核函数选择径向基核(RBF)函数。

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (27)$$

式中 $2\sigma^2$ 为核函数的宽度。

将以上两式计算结果代入到 $f(x) = \mathbf{r}\phi(x) + b$ 中, 得到分类函数为:

$$f(x) = \alpha_i Y_i K(x_i, x_j) + b = 0 \quad (28)$$

LSSVM 是一个二分类模型, 变压器故障繁多, 且故障数据呈非线性, 因此需要将二分类 LSSVM 推广到 K_0 分类。LSSVM 就是寻找一个决策函数 $f(x)$ 使样本分成 K_0 类型。

4.2 KPCA-IPOA-LSSVM 故障诊断模型

为提高变压器故障诊断准确率, 在数据处理上采用 KPCA 对数据进行降维, 利用 IPOA 对 LSSVM 的参数 C 和 g 来进行优化, 然后建立 KPCA-IPOA-LSSVM 的诊断模型, 诊断流程图如图 8 所示。




图 8 KPCA-IPOA-LSSVM 流程图

Fig. 8 KPCA-IPOA-LSSVM flowchart

诊断流程如下。

步骤 1: 线性不可分的故障数据经过数据降维, 保留最主要的特征量, 并将主要特征离差标准化处理, 划分为训练集和测试集。

步骤 2: POA 算法初始化阶段引入 logistic 混沌映射, 其中种群数量为 30, 迭代次数 1 000, 维度为 5。

步骤 3: 计算鸚鵡个体的适应度值, 保留适应度值最高的最优个体。

步骤 4: 通过位置更新公式对第一阶段和第二阶段鸚鵡个体进行位置更新。

步骤 5: 比较更新后的鸚鵡的最优位置与更新前的最优位置, 按照适应度值最高的进行保留, 若没达到最大迭代次数返回步骤 4。

步骤 6: 输出参数 C 和 g , 获取 KPCA-IPOA-LSSVM 模型, 对变压器故障进行诊断。

4.3 实例分析

根据文献[24–26]选取变压器故障数据为 421 组, 表 4 是数据样本分布的具体情况。

表 4 中, 训练集与测试集按照 7 : 3 的比例来进行划分, 训练集分为 295 组, 测试集分为 126 组; 故障类型分别为中低温过热故障、高温过热故障、局部放电故障、低能放电故障、高能放电故障以及正常状态 6 种类型, 并为其按照 1—6 的编码进行排序。

表 4 数据集样本分布

Tab. 4 Sample distribution of the dataset

标签	故障类型	样本数	训练集	测试集
1	中低温过热	71	50	21
2	高温过热	71	50	21
3	局部放电	69	48	21
4	低能放电	72	50	22
5	高能放电	71	50	21
6	正常状态	67	47	20

把 421 组数据采用 PCA 与 KPCA 进行特征提取, 经过 PCA 降维后的数据作为 PCA-IPOA-SVM 诊断模的输入, KPCA 降维的数据作为其余诊断模型的输入, 诊断结果对比如图 9—13 所示。




图 9 PCA-IPOA-SVM 诊断结果

Fig. 9 PCA-IPOA-SVM diagnostic results

由图 9—10 可知, PCA-IPOA-SVM 诊断模型的准确率为 75.93%, 而 KPCA-IPOA-SVM 诊断模型的准确率为 82.71%, 准确率提升 6.78%, 结果表明, 在处理非线性问题上, KPCA 比 PCA 的实际效果更可靠。




图 10 KPCA-IPOA-SVM 诊断结果

Fig. 10 KPCA-IPOA-LSSVM diagnostic results




图 11 KPCA-WOA-LSSVM 诊断结果

Fig. 11 KPCA-WOA-LSSVM diagnostic results

图 11—12 中, 这两个诊断模型中分别采用 WOA 和 POA 优化算法对 LSSVM 进行优化, KPCA-WOA-LSSVM 诊断模型的诊断精度为 82.37%, KPCA-POA-LSSVM 诊断模型的诊断精度为 86.78%, 比前者提高了 4.41%, 由此可以看出, POA 优化算法比 WOA 优化算法具有更快的收敛速度和寻优能力, 对最小二乘支持向量机的优化更加突出, 使诊断结果更加准确。

图 13 中 KPCA-IPOA-LSSVM 诊断模型的诊断结果为 94.24%, 相较于 KPCA-IPOA-SVM 的诊断模型的诊断精度提升了 11.53%。对比结果可得 LSSVM 比 SVM 具有良好的拟合性能, 泛化能力更强, 分类效果更好。KPCA-IPOA-LSSVM 诊断模型




图 12 KPCA-POA-LSSVM 诊断结果

Fig. 12 KPCA-POA-LSSVM diagnostic results




图 13 KPCA-IPOA-LSSVM 诊断结果

Fig. 13 KPCA-IPOA-LSSVM diagnostic results

在中低温过热、高温过热以及局部放电故障较为敏感，对正常状态诊断效果相对低一些，但整体诊断效果在 94% 以上，结果表明，本文将通过 KPCA 进行特征提取的故障数据作为输入，经过多策略改进的鸚鵡优化算法结合 LSSVM 的诊断模型对故障进行诊断，其诊断准确率是所有参与对比的诊断模型中最高的，证明了 KPCA-IPOA-LSSVM 有效提高了故障诊断的准确率。

5 结论

为了解决传统变压器故障诊断问题中数据量庞大、无关变量干扰大引起诊断正确率低问题，本文采用 KPCA 技术对原始数据集进行降维，选出相关

性最高的 8 组数据，完成对数据的预处理。

本文提出 IPOA 算法用以优化 LSSVM 模型参数，IPOA 引入 logistic 混沌映射策略对算法进行初始化，自适应权重策略和透镜成像反向学习策略帮助算法跳出局部最优以提高收敛精度，并通过实验验证了改进算法的有效性。

最后建立了 KPCA-IPOA-LSSVM 模型，该模型的准确率为 94.24%，相较于 PCA-IPOA-SVM、KPCA-IPOA-SVM、KPCA-WOA-LSSVM、KPCA-POA-LSSVM 模型的故障诊断的准确率分别提升了 18.31%、11.53%、11.87%、7.46%。本文提出的诊断模型对提高故障的分类效率和准确率具有一定的理论研究和实际工程应用意义。

参考文献

- [1] 李多,张莲,赵娜,等.基于混合特征选择和 INGO-DHKELM 的变压器故障诊断方法[J].南方电网技术,2024,18(8):19-28.
LI Duo, ZHANG Lian, ZHAO Na, et al. Transformer fault diagnosis method based on hybrid feature selection and INGO-DHKELM [J]. Southern Power System Technology, 2024, 18(8): 19-28.
- [2] 郑业爽,李世春,鲁玲.基于多策略 ISOA 优化 SVM 的变压器故障诊断研究[J].智慧电力,2023,51(2):38-44.
ZHENG Yeshuang, LI Shichun, LU Ling. Transformer fault diagnosis based on multi-strategy ISOA optimized SVM [J]. Smart Power, 2023, 51(2): 38-44.
- [3] 代杰杰,宋辉,盛戈峰,等.采用 LSTM 网络的电力变压器运行状态预测方法研究[J].高电压技术,2018,44(4):1099-1106.
DAI Jiejie, SONG Hui, SHENG Gehao, et al. Prediction method for power transformer running state based on LSTM network [J]. High Voltage Engineering, 2018, 44(4): 1099-1106.
- [4] 王雨虹,王志中,付华,等.多策略改进麻雀算法与 BiLSTM 的变压器故障诊断研究[J].仪器仪表学报,2022,43(3):87-97.
WANG Yuhong, WANG Zhizhong, FU Hua, et al. Research on transformer fault diagnosis based on the improved multi-strategy sparrow algorithm and BiLSTM [J]. Journal of Scientific Instrument, 2022, 43(3): 87-97.
- [5] 张弛,吴东,王伟,等.不平衡样本下基于变分自编码器预处理深度学习和 DGA 的变压器故障诊断方法[J].南方电网技术,2021,15(3):68-74.
ZHANG Chi, WU Dong, WANG Wei, et al. Transformer fault diagnosis method based on variational auto-encoders preprocessing deep learning and DGA for unbalanced samples [J]. Southern Power System Technology, 2021, 15(3): 68-74.
- [6] 徐龙舞,张英,张倩,等.基于正交实验法改进的蝠鲼算法优化 BP 在变压器故障诊断上的研究[J].南方电网技术,2022,16(7):46-54.
XU Longwu, ZHANG Ying, ZHANG Qian, et al. Orthogonal experiment method based improved MRFO algorithm to

- optimize BP in transformer fault diagnosis[J]. Southern Power System Technology, 2022, 16(7): 46 – 54.
- [7] 周晓华,冯雨辰,胡旭初,等.基于秃鹰搜索算法优化SVM的变压器故障诊断[J].南方电网技术, 2023, 17(6): 99 – 106, 116.
ZHOU Xiaohua, FENG Yuchen, HU Xuchu, et al. Transformer fault diagnosis based on SVM optimized by bald eagle search algorithm[J]. Southern Power System Technology, 2023, 17(6): 99 – 106, 116.
- [8] 咸日常,范慧芳,李飞,等.基于改进GSA-SVM模型的电力变压器故障诊断[J].智慧电力, 2022, 50(6): 50 – 56.
XIAN Zhenzhang, FAN Huifang, LI Fei, et al. Power transformer fault diagnosis based on improved GSA-SVM model[J]. Smart Power, 2022, 50(6): 50 – 56.
- [9] 李黄曼,张勇,张瑶,等.基于ISSA优化SVM的变压器故障诊断研究[J].电子测量与仪器学报, 2021, 35(3): 123 – 129.
LI Huangman, ZHANG Yong, ZHANG Yao, et al. Study of transformer fault diagnosis based on improved sparrow search algorithm optimized support vector machine [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(3): 123 – 129.
- [10] 周威振,马越,邓集瀚,等.基于FedAVG-SA-BP的变压器DGA故障诊断[J].变压器, 2023, 60(9): 31 – 35.
ZHOU Weizhen, MA Yue, DENG Jihan, et al. Transformer DGA fault diagnosis based on FedAVG-SA-BP [J]. Transformer, 2023, 60(9): 31 – 35.
- [11] 张宏杰,陈贵凤,闫宏伟,等.基于SMOTE与Bayes优化的LSTM网络变压器故障诊断[J].中国电力, 2023, 56(10): 164 – 170.
ZHANG Hongjie, CHEN Guifeng, YAN Hongwei, et al. Fault diagnosis of LSTM network transformer based on SMOTE and Bayes optimization [J]. Electric Power, 2023, 56(10): 164 – 170.
- [12] 高松,刘志刚,徐建芳,等.基于模型诊断和专家系统的牵引变压器故障诊断研究[J].铁道学报, 2013, 35(7): 42 – 49.
GAO Song, LIU Zhigang, XU Jianfang, et al. Research on fault diagnosis for traction transformer on the basis of model-based diagnosis and expert system [J]. Journal of the China Railway Society, 2013, 35(7): 42 – 49.
- [13] 王晶,许素安,洪凯星,等.基于DGA特征量优选与GA-SVM的变压器故障诊断模型[J].变压器, 2020, 57(12): 36 – 40, 46.
WANG Jing, XU Su'an, HONG Kaixing, et al. Transformer based on DGA feature quantity optimization and GA-SVM fault diagnosis mode [J]. Transformer, 2020, 57(12): 36 – 40, 46.
- [14] 谢国民,倪乐水,曹媛.基于VSRP与 β -GWO-SVM的变压器故障辨识方法[J].高电压技术, 2021, 47(10): 3635 – 3641.
XIE Guomin, NI Leshui, CAO Yuan. Transformer fault identification method based on VSRP and β -GWO-SVM [J]. High Voltage Engineering, 2021, 47(10): 3635 – 3641.
- [15] 李云淦,咸日常,张海强,等.基于改进灰狼算法与最小二乘支持向量机耦合的电力变压器故障诊断方法[J].电网技术, 2023, 47(4): 1470 – 1478.
LI Yunhao, XIAN Richang, ZHANG Haiqian et al. Fault diagnosis for power transformers based on improved grey wolf algorithm coupled with least squares support vector machine [J]. Power System Technology, 2023, 47(4): 1470 – 1478.
- [16] LI Z Y, CAO Z J, LI M Y. Transformer fault diagnosis based on LSSVM with improved fruit fly optimization [J]. Water Resources and Power, 2016(12): 112 – 123.
- [17] 武文栋,施保华,郑传良,等.基于KPCA-ISSA-KELM的光伏阵列故障诊断方法[J].智慧电力, 2022, 50(11): 69 – 76.
WU Wendong, SHI Baohua, ZHENG Chuanliang, et al. Fault diagnosis method of PV array based on KPCA-ISSA-KELM [J]. Smart Power, 2022, 50(11): 69 – 76.
- [18] 张国治,陈康,方荣行,等.基于DGA与鲸鱼算法优化Logit Boost-决策树的变压器故障诊断方法[J].电力系统保护与控制, 2023, 51(7): 63 – 72.
ZHANG Guozhi, CHEN Kang, FANG Rongxing, et al. Transformer fault diagnosis based on DGA and a whale algorithm optimizing a LogitBoost-decision tree [J]. Power System Protection and Control, 2023, 51(7): 63 – 72.
- [19] TROJOVSK P, DEGHANI M. Pelican optimization algorithm: a novel nature-inspired algorithm for engineering applications [J]. Sensors (Basel, Switzerland), 2022, 22(3): 133 – 142.
- [20] 李鹏,陈守静,杨山山,等.基于Logistic映射的果蝇算法优化Otsu图像分割方法[J].国外电子测量技术, 2022, 41(7): 9 – 17.
LI Peng, CHEN Shoujing, YANG Shanshan, et al. Otsu image segmentation method optimized by fruit fly optimization algorithm based on Logistic mapping [J]. Foreign Electronic Measurement Technology, 2022, 41(7): 9 – 17.
- [21] 安国庆,史哲文,马世峰,等.基于RF特征优选的WOA-SVM变压器故障诊断[J].高压电器, 2022, 58(2): 171 – 178.
AN Guoqing, SHI Zhewen, MA Shifeng, et al. Fault diagnosis of WOA-SVM transformer based on RF feature optimization [J]. High Voltage Apparatus, 2022, 58(2): 171 – 178.
- [22] 张娜,任强,刘广忱,等.基于VMD-GWO-ELMAN的光伏功率短期预测方法[J].中国电力, 2022, 55(5): 57 – 65.
ZHANG Na, REN Qiang, LIU Guangzheng, et al. Short-term PV power prediction method based on VMD-GWO-ELMAN [J]. Electric Power, 2022, 55(5): 57 – 65.
- [23] KAI Z, KE Z, RUI B. Prediction of gas explosion pressures: A machine learning algorithm based on KPCA and an optimized LSSVM [J]. Journal of Loss Prevention in the Process Industries, 2023(83): 121 – 132.
- [24] 孙琛.基于机器学习算法的变压器故障诊断[D].上海:上海交通大学, 2019.
- [25] 田晓飞.基于改进蝙蝠算法优化支持向量机的变压器故障诊断研究[D].成都:西华大学, 2019.
- [26] 尹金良.基于相关向量机的油浸式电力变压器故障诊断方法研究[D].北京:华北电力大学, 2013.

收稿日期: 2023-11-16; 网络首发日期: 2024-06-30

作者简介:

陈尧(1997), 男, 通信作者, 硕士研究生, 研究方向为智能电网理论及应用, 1520278880@qq.com;

周连杰(1968), 男, 高级工程师(教授级), 硕士, 研究方向为智能电网理论及应用。